

UNIVERSITÉ DU QUÉBEC À TROIS-RIVIÈRES

CARACTÉRISATION DU SIGNAL PAR ANALYSE DES DONNÉES DE SUBSTITUTION

THÈSE PRÉSENTÉE
COMME EXIGENCE PARTIELLE DU
DOCTORAT EN GÉNIE ÉLECTRIQUE

PAR
MANOUANE CAZA-SZOKA

FÉVRIER 2020

Université du Québec à Trois-Rivières

Service de la bibliothèque

Avertissement

L'auteur de ce mémoire ou de cette thèse a autorisé l'Université du Québec à Trois-Rivières à diffuser, à des fins non lucratives, une copie de son mémoire ou de sa thèse.

Cette diffusion n'entraîne pas une renonciation de la part de l'auteur à ses droits de propriété intellectuelle, incluant le droit d'auteur, sur ce mémoire ou cette thèse. Notamment, la reproduction ou la publication de la totalité ou d'une partie importante de ce mémoire ou de cette thèse requiert son autorisation.

UNIVERSITÉ DU QUÉBEC À TROIS-RIVIÈRES

DOCTORAT EN GÉNIE ÉLECTRIQUE (Ph. D.)

Direction de recherche :

M. Daniel Massicotte

Directeur de recherche

M. Martin Descarreaux

Codirecteur de recherche

Jury d'évaluation

M. Daniel Massicotte

Directeur de recherche

M. Soussou Kelouwani

Président du jury

M. Messaoud Ahmed Ouameur

Évaluateur

M. Benoit Gosselin

Évaluateur externe

Thèse soutenue le 06 12 2019

RÉSUMÉ

La thèse présente l'analyse par données de substitution comme caractéristique. Alors que la littérature présente la méthode uniquement comme test d'hypothèse qui a pour but de vérifier la non-linéarité de séries de données, il est suggéré ici d'aller plus loin en l'utilisant pour extraire une information utile. Après avoir adapté la méthode pour obtenir un score de non-linéarité capable d'identifier différentes séries non-linéaires, des applications et interprétations sont suggérées. La méthode pour obtenir un score est utilisée conjointement aux méthodes d'estimation de la dimension fractale d'Higuchi et de Katz.

Deux problématiques sont abordées avec des données expérimentales de matrices de capteurs d'électromyographie de surface à l'appui. Ces tests permettent de montrer que l'analyse par données de substitution peut contenir de l'information utile expérimentalement. Premièrement, la détection de la lombalgie chronique non spécifique est réalisée avec l'aide des scores. Des performances supérieures aux méthodes linéaires sont démontrées, avec des taux de succès dépassant les 90%. Deuxièmement, la classification de mouvements est approchée par méthode linéaire, fractale et par l'analyse des données de substitution. Les performances obtenues montrent clairement la présence d'information dans les scores de données de substitution. Cependant, la participation des scores aux meilleures performances est limitée. Il est cependant possible d'entrevoir que l'utilisation des scores de non-linéarité pourrait permettre de dépasser les résultats déjà intéressants avoisinant les 94% de succès sur 15 mouvements.

De nouvelles interprétations de l'analyse par données de substitution sont présentées. En plus de l'interprétation traditionnelle se limitant à affirmer que le signal ne peut avoir été créé par un système stochastique linéaire et invariant dans le temps, trois catégories d'interprétations sont

identifiées. Pour chaque catégorie, un exemple d'interprétation est donné. Il est montré que l'analyse par données de substitution est sensible à la nature non-aléatoire du spectre de phase, à la synchronisation de potentiels d'action musculaires et a des artefacts comme les effets de fenêtrage liés à la longueur limitée des séries de données.

Il est espéré que les idées mises de l'avant dans cette thèse puissent s'appliquer à une vaste portion des problèmes faisant appel à l'analyse des signaux par méthodes non-linéaires.

REMERCIEMENTS

Je voudrais tout d'abord à remercier le professeur Daniel Massicotte pour le soutien que je qualiferais d'exceptionnel tout au long de mes études doctorales. J'ai apprécié sa grande disponibilité (dont j'ai parfois abusée), sa rigueur et sa confiance. Je considère qu'il a pris beaucoup de risques avec moi, me laissant aller sur des sujets difficiles mais intéressants.

Je remercie le professeur Martin Descarreaux, Jacques Abboud et l'équipe du Groupe de recherche sur les affections neuromusculosquelettiques (GRAN) pour m'avoir donné l'occasion de travailler sur un sujet des plus intéressants.

Je tiens à souligner mon appréciation au professeur François Nougarou pour toutes les discussions et la direction apportée à mes travaux.

Je veux également remercier les membres du jury, professeurs Soussou Kelouwani et Messaoud Ahmed Ouameur de l'Université du Québec à Trois-Rivières ainsi que professeur Benoit Gosselin de l'Université Laval pour leur intérêt envers mes travaux.

Ma conjointe, Marie-Lène Bédard, mérite un certificat d'éternelle reconnaissance pour tout son support au travers les hauts et les bas de ces dernières années. Aussi, mes enfants, Rosa Elena, Daniela Véronique et Charléloï, je les remercie pour la joie qu'ils m'apportent et pour leur intérêt à chercher à comprendre ce que fait leur papa dans la vie. À mes parents, je leur dis merci de m'avoir toujours encouragé à la persévérance et au dépassement de soi. Je tiens finalement à remercier Denis Marcotte, Véronique Cloutier, Steve Lapointe, Xavier Boucher, Adam Galarneau, Philippe et Christophe Bernard pour leur amitié qui a été plus qu'appréciée.

TABLE DES MATIÈRES

Résumé.....	v
Remerciements.....	vii
Table des matières.....	viii
Liste des figures	xiv
Liste des tableaux.....	xviii
Liste des acronymes	xix
Chapitre 1: Introduction	1
1.1 Parallèle avec le test d'hypothèse sur une moyenne	1
1.2 Applications prévues	2
1.3 SA dans la littérature	3
1.4 Structure de la thèse	4
Chapitre 2: Comparaison entre le score proposé et celui de Theiler.....	7
2.1 Séries non-linéaires classiques	7
2.1.1 Suite logistique	8
2.1.2 Suite de Hénon	8
2.1.3 Attracteur de Rössler	8
2.1.4 Bruit coloré.....	9

2.2 Méthodes numériques	9
2.2.1 Méthodes de SA	10
2.2.2 Méthodes fractales.....	12
2.2.3 Fenêtrage	13
2.3 Résultats	14
2.4 Discussion	15
Chapitre 3: Développement de la SA pour la détection de lombalgie chronique non spécifique	17
3.1 Contexte	19
3.2 Revue de la littérature	20
3.2.1 Caractéristiques simples, capteur unique sEMG	20
3.2.2 Caractéristiques avancées, capteur sEMG unique	20
3.2.3 Caractéristiques simples, capteurs sEMG multiples.....	21
3.2.4 Caractéristiques avancées, capteurs sEMG multiples	22
3.3 Méthodologie	23
3.3.1 Tâches statiques et fenêtre fixe.....	23
3.3.2 Utilité des matrices sEMG pour l'analyse de séries temporelles	24
3.3.3 Fléau de la dimensionnalité et validation croisée	25
3.3.4 Tests multiples.....	26
3.3.5 Proposition d'une méthode linéaire	27
3.3.6 Approche non-linéaire proposée.....	28

3.3.7 Procédure expérimentale	33
3.4 Résultats	33
3.4.1 Comparaison des caractéristiques.....	34
3.4.2 Principaux résultats de classification.....	36
3.5 Conclusion et contributions.....	39
Chapitre 4: Nouvelles interprétations de la SA	43
4.1 Spectre de la phase non-aléatoire	45
4.1.1 Dirac versus bruit blanc.....	46
4.1.2 Courbe à distribution parfaitement Gaussienne.....	54
4.2 Synchronisation des potentiels d'action et vitesse de conduction	73
4.2.1 Relation SA et synchronisation	74
4.2.2 Définitions de la synchronisation dans la littérature.....	75
4.2.3 Model employé.....	77
4.2.4 Modèles plus réalistes.....	77
4.2.5 Simulations faites en exemple	78
4.2.6 Résultats de simulation.....	79
4.2.7 Variabilité des caractéristiques	83
4.2.8 Perspectives	85
4.3 Effet du fenêtrage	87
4.3.1 Méthode de fenêtrage pour la SA	87

4.3.2 Analyse des performances	90
4.3.3 Simulation des performances sur hypothèse nulle	92
4.3.4 Effet sur l'information	96
4.3.5 Discussion	100
Chapitre 5: Application de la SA à la classification de mouvements par sEMG	103
5.1 Brève revue de la littérature	104
5.2 Contributions	106
5.3 Données et prétraitement.....	107
5.3.1 Description des données	107
5.3.2 Absence de préfiltres	108
5.3.3 Filtrage spatial	109
5.3.4 Fenêtrage des données	110
5.3.5 Mouvement 0 (repos)	110
5.4 Systèmes et méthodologie	112
5.4.1 Caractéristiques utilisées	112
5.4.2 Paramètres des méthodes fractales	114
5.4.3 Algorithme de classification utilisé	115
5.4.4 Nombre de neurones.....	116
5.4.5 Initialisations multiples des poids du réseau de neurones	116
5.4.6 Problématique des mouvements 2 et 8	117

5.4.7 Utilisation du filtre médian.....	118
5.4.8 Temps de réponse	121
5.4.9 Problème d'invariance de la variance (et d'autres caractéristiques).....	121
5.4.10 Séparation des données.....	123
5.5 Résultats	124
5.5.1 Inférence statistique pour les performances obtenues	124
5.5.2 Résultats principaux	127
5.5.3 Augmentation du taux d'erreur selon le temps.....	129
5.5.4 Inversion des groupes d'entraînement et validation	133
5.6 Discussion	135
Chapitre 6: Conclusion.....	139
6.1 Contribution à l'étude des systèmes sEMG	139
6.2 Contributions à l'utilisation de la SA	140
6.3 Contributions à l'interprétation de la SA	141
6.4 Questions restantes	142
6.4.1 Lien avec les autres travaux faits au laboratoire GRAN	142
6.4.2 Filtrage spatial	142
6.4.3 Stationnarité.....	142
6.4.4 SA des résidus	143
6.4.5 SA et blanchissage des données	143

6.4.6 SA et filtrage linéaire.....	143
6.4.7 Spectre de non-linéarité.....	143
6.4.8 SA et quantification du signal	144
6.4.9 SA et bruit de mesure	144
6.4.10 Effet du fenêtrage selon l'ordre de l'atténuation du processus de l'hypothèse nulle	144
6.5 Axes de recherches découlant de la thèse	145
Références.....	147
Annexe 1: Applications de la SA dans la littérature	159
Annexe 2: Choix du nombre de séries de substitution	163
2.1 Analytical derivation of the effect of the number of surrogate series on the score Z	165
Annexe 3: Analyse de l'impact du biais causé sur la SA par le fenêtrage	169
Annexe 4: Effet de la répartition aléatoire des données sur la validation croisée	177
Annexe 5: Analyse de données de substitution du spectre de la longueur de courbe sous-échantillonné	181
Annexe 6: Publications	185
Annexe 7: Code Matlab® pour la SA et les FDs	187
7.1 Code de la SA.....	187
7.2 Code des dimensions fractales	188

LISTE DES FIGURES

Figure 2-1 SA à deux scores et fenêtrage.....	9
Figure 2-2 Classification de séries non-linéaires ($N = 256$)	14
Figure 2-3 Classification de séries non-linéaires ($N = 1024$)	15
Figure 3-1 Système de classification utilisant la fréquence médiane	28
Figure 3-2 Analyse par données de substitution	32
Figure 3-3 Connectivité des entrées du réseau de neurones	33
Figure 3-4 Relation entre les caractéristiques linéaires et non-linéaires	34
Figure 3-5 Relation entre les pentes des caractéristiques linéaires et non-linéaires	35
Figure 3-6 Relation entre la dimension fractale et la pente de la fréquence médiane	35
Figure 3-7 Performances de la méthode basée sur l'analyse par données de substitution.....	38
Figure 3-8 Impact du taux de régulation sur les performances du réseau de neurones.....	38
Figure 4-1 Bruit blanc, distribution, spectre de puissance et spectre de phase.....	47
Figure 4-2 Randomisation de la phase d'impulsion de Dirac, distribution, spectre de puissance et spectre de phase.	47
Figure 4-3 Détection du Dirac par SA basée sur Katz.....	49
Figure 4-4 Détection du Dirac par SA basée sur Higuchi.....	49
Figure 4-5 Détection du Dirac par Kolmogorov-Smirnov.....	49
Figure 4-6 Détection du Dirac par Shapiro-Wilk	50
Figure 4-7 Détection du Dirac par seuil, Bonferroni et Monte Carlo.....	50
Figure 4-8 Détection du Dirac par seuil, SNR pour taux de succès de 50%	51

Figure 4-9 Détection du Dirac par seuil, comparaison du test unilatéral et bilatéral.....	52
Figure 4-10 Résumé de la détection du Dirac, SNR pour taux de succès de 50%.....	53
Figure 4-11 Détection du Dirac sans normalisation pour le nombre de données.....	54
Figure 4-12 Impulsion gaussienne et sa distribution	54
Figure 4-13 Impulsion à distribution gaussienne	55
Figure 4-14 Problème de discontinuité circulaire de la courbe à distribution gaussienne	56
Figure 4-15 Impulsion à distribution gaussienne circulairement continue	56
Figure 4-16 Phase corrigée de l'impulsion à distribution gaussienne	57
Figure 4-17 Impulsion à distribution gaussienne à début et fin nulle	58
Figure 4-18 Impulsion à distribution gaussienne bruitée	59
Figure 4-19 Détection de l'impulsion à distribution gaussienne bruitée.....	59
Figure 4-20 Distribution du bruit fait par données de substitution.....	60
Figure 4-21 Résumé de la détection de l'impulsion à distribution gaussienne, SNR pour taux de succès de 50%	61
Figure 4-22 Impulsion à distribution gaussienne pour un signal BPSK de 8 bits	62
Figure 4-23 Détection de l'impulsion à distribution gaussienne pour un signal BPSK de 8 bits.....	62
Figure 4-24 Exemple de signal ECG	63
Figure 4-25 ECG bruité à 0 dB	63
Figure 4-26 ECG après filtrage.....	64
Figure 4-27 ECG après fenêtrage	64
Figure 4-28 Exemple de SA pour détection de l'ECG	64
Figure 4-29 Exemple de SA pour détection de l'ECG, 5000 séries de substitution.....	65
Figure 4-30 Performance de détection de l'ECG.....	65
Figure 4-31 Séquence ECG non bruité	66

Figure 4-32 Séquence ECG, 10 dB	67
Figure 4-33 Séquence ECG après filtrage	67
Figure 4-34 Score de la SA selon le temps pour l'ECG	68
Figure 4-35 Score de la SA selon le temps, filtré	68
Figure 4-36 Détection du signe du score de la SA.....	69
Figure 4-37 Résultat de la détection de battement cardiaque par la SA, 10dB.....	69
Figure 4-38 Séquence ECG bruitée à 0dB	70
Figure 4-39 Résultat de la détection de battement cardiaque par la SA, 0dB.....	70
Figure 4-40 Performances d'estimation du rythme cardiaque, référencées sur le seuil sans bruit.....	71
Figure 4-41 Performances d'estimation du rythme cardiaque, référencées sur les meilleurs résultats de chaque méthode.....	72
Figure 4-42 Signal de base, exemple de signal non synchronisé et signaux avec taux de synchronisation faibles.....	79
Figure 4-43 Résultat moyens de la SA selon le taux de synchronisation pour différentes vitesses de conductions	80
Figure 4-44 Caractéristiques moyennes selon le taux de synchronisation pour différentes vitesses de conduction.....	82
Figure 4-45 Caractéristiques selon le taux de synchronisation pour différentes vitesses de conduction	84
Figure 4-46 Quatre méthode d'application du fenêtrage adapté pour la SA	89
Figure 4-47 Fenêtre de Tukey pour différents paramètres	91
Figure 4-48 Effet du fenêtrage sur la SA selon le nombre de données avec différentes bandes passantes et ordre de processus	93
Figure 4-49 Performances des méthodes de fenêtrage pour la SA, paramètre de fenêtre fixe.	94

Figure 4-50 Performances des méthodes de fenêtrage pour la SA, variation du paramètre de la fenêtre.	95
.....
Figure 4-51 Détection de la série logistique	98
Figure 4-52 Courbes ROC de détection de la série logistique.....	99
Figure 5-1 Exemple d'un canal sEMG monopolaire et avec différentiel simulé	108
Figure 5-2 Spectres de puissances des signaux sEMG monopolaire et avec différentiel simulé.....	109
Figure 5-3 Courbe ROC de la détection du mouvement 0, différent nombre de fenêtres transitoires.	
.....	111
Figure 5-4 Exemple de caractéristique de signaux selon le temps pour un capteur avec mouvement 0.	
.....	113
Figure 5-5 Exemple de caractéristique de signaux selon le temps pour un capteur sans mouvement 0.	
.....	114
Figure 5-6 Exemple de réseau de neurone employé pour la détection de mouvement.....	116
Figure 5-7 Performances pour différentes initialisations	117
Figure 5-8 Matrice de confusion, problème du mouvement 2.....	118
Figure 5-9 Performances du filtre médian.....	120
Figure 5-10 Représentation proportionnelle des performances du filtre médian	120
Figure 5-11 Erreur cumulative selon le temps (en terme de fenêtre de données)	129
Figure 5-12 Taux d'erreur selon l'expérience, groupe de test.....	130

LISTE DES TABLEAUX

Tableau 3-1 Corrélation entre différentes caractéristiques	36
Tableau 3-2 Performances de la méthode linéaire proposée basée sur la fréquence médiane .	37
Tableau 5-1 Déviation standard du taux de succès selon l'hypothèse nulle.....	126
Tableau 5-2 Exemples de valeurs-p de différentes différences de proportions	126
Tableau 5-3 Performance avec mouvement 2.....	127
Tableau 5-4 Performance sans mouvement 2	128
Tableau 5-5 Pentes du taux d'erreur pour du groupe de validation.....	131
Tableau 5-6 Pentes du taux d'erreur pour du groupe de test	132
Tableau 5-7 Performances avec inversion de l'ordre des groupes entraînement et validation	134
Tableau 5-8 Comparaison des performances selon l'ordre des groupes Entrainement, Validation et Test	135
Tableau A 1-1 Bibliographie sur les applications de la SA	159
Tableau A 3-1 Statistics of the Offset and Surrogate Distributions and False Positive Rates, $a_1=0.995$	172
Tableau A 4-1 Résultat pour répartition aléatoire entre les groupes, fenêtre par fenêtre	178
Tableau A 4-2 Résultat pour répartition aléatoire entre les groupes, mouvement par mouvement	179
Tableau A 4-3 Répartition aléatoire entre les groupes, expérience par expérience.....	180

LISTE DES ACRONYMES

ARMA : Modèles autorégressifs et moyenne mobile

BP : Bande passante

BPSK : Modulation par changement de phase (*Binary Phase Shift Keying*)

ECG : Électrocardiogramme

EEG : Électroencéphalogramme

EMG : Électromyogramme

FD : Dimension fractale (*Fractal Dimension*)

FFT : Transformée de Fourier rapide (*Fast Fourier Transform*)

ICDF : Fonction de distribution cumulative inverse (*inverse cumulative distribution function*)

MDF : Fréquence médiane (*Median Frequency*)

NN : Réseau de neurones artificiel (*Neural Network*)

PLI : Interférence des du réseau d'alimentation électrique (*Power Line Interference*)

ROC : Courbe de sensibilité/spécificité (*Receiver Operating Characteristic*)

SA : Analyse par données de substitution (*Surrogate Analysis*)

sEMG : Électromyogramme de surface

Chapitre 1: INTRODUCTION

L’analyse par données de substitution [THE92] (SA) est une méthode permettant de tester la non-linéarité d’un signal à partir d’une caractéristique non-linéaire. L’idée de la thèse est d’utiliser la SA comme caractéristique du signal. Des exemples d’applications sont donnés, particulièrement dans le contexte d’analyse de données de matrices de capteurs d’électromyographie de surface. Aussi, l’interprétation de la SA est développée. Une panoplie de caractéristiques non-linéaires pourraient être utilisées avec la SA, mais la dimension fractale (FD) sera la seule considérée. Bien que les données de substitution soient utilisées fréquemment pour valider l’aspect non-linéaire d’un signal, l’utilisation des résultats comme caractéristique du signal servant à produire une classification n’est pas présente dans la littérature. De plus, l’interprétation de SA est généralement limitée à affirmer que le signal est de nature non-linéaire, ou non-stationnaire. Même si plusieurs milliers de publications ont fait référence à cette méthode, plusieurs questions fondamentales sont restées ignorées ou peu développées. La thèse met clairement en valeur la méthode de la SA et fait avancer sa compréhension.

L’introduction de la thèse illustre premièrement son approche par un parallèle avec un test d’hypothèse mieux connu. Une perspective sur le type de problématiques qui peuvent bénéficier des nouvelles caractéristiques est développée. Une revue de la littérature de l’utilisation actuelle de la SA est donnée. Finalement, les chapitres de la thèse sont résumés.

1.1 PARALLÈLE AVEC LE TEST D’HYPOTHÈSE SUR UNE MOYENNE

L’idée d’utiliser la SA comme caractéristique du signal s’illustre aisément en considérant le test d’hypothèse sur une moyenne. Par exemple, on peut s’intéresser à savoir si la moyenne d’un

échantillon est nulle. Le test d'hypothèse sur la moyenne indiquera si la moyenne de l'échantillon est différente de zéro de manière statistiquement significative.

La taille d'effet [FRI12] (*effect size*) quant à elle permet de quantifier la déviation par rapport à la moyenne, en unités de déviations standards. Cette taille d'effet est généralement utilisée pour quantifier l'importance d'une relation statistiquement significative. L'idée de la thèse, appliquée au test sur la moyenne, est d'utilisé la taille d'effet comme caractéristique du signal. Cette caractéristique peut s'utiliser notamment comme entrée d'un algorithme de classification, tel un réseau de neurones artificiels.

De retour à la SA, celle-ci donne un score similaire en unités de déviations standards. La thèse suggère donc d'utiliser ce score comme caractéristique du signal.

1.2 APPLICATIONS PRÉVUES

Principe de parcimonie oblige, les applications pouvant être susceptibles de bénéficier des nouvelles caractéristiques sont celles dont les méthodes linéaires échouent. Les problèmes fortement non-linéaires sont principalement visés. Aussi, il arrive souvent que des caractéristiques linéaires réussissent à produire une bonne partie du résultat désiré, mais que pour aller plus loin, elles restent bloquer. Par exemple, un problème de classification pourrait être limité à 95% de succès avec une méthode linéaire, mais ajouter d'autres caractéristiques linéaires ne pourrait améliorer les résultats. Il faut penser à d'autres approches pour obtenir des performances supérieures. Comme il sera vu plus loin, les caractéristiques non-linéaires sont souvent fortement corrélées aux caractéristiques linéaires. La thèse propose des caractéristiques fortement décorrélées de celles linéaires. Il est donc attendu que les problématiques dont les

performances stagnent avec l'utilisation de méthodes linéaires auraient intérêt d'être abordées par ce qui est proposé.

1.3 SA DANS LA LITTÉRATURE

À l'Annexe 1 est donné une liste des principales références faisant appel à la SA comme tests d'hypothèse. On trouve que la majorité se retrouve dans le domaine biomédical. Quelques autres se trouvent dans les domaines de sciences de l'environnement et de l'économie. Par contre, l'étude a été limitée aux articles hautement cités et il est connu que certains domaines citent plus que d'autres. L'idée principale est dans la plupart des cas de montrer qu'une série est bien non-linéaire et ainsi de justifier l'utilisation de méthodes non-linéaires ou de chercher à interpréter les résultats de détection ou classification avec l'utilisation de caractéristiques non-linéaires. Par exemple :

- L'approche multi-fractale pour analyser les marchés boursiers est justifiée dans [OSW05],
- Pour l'étude de l'électroencéphalogramme, [SUB10] montre qu'il est justifié d'utiliser certaines méthodes non-linéaires,
- L'utilisation de méthodes non-linéaire pour la détection d'Alzheimer est suggérée dans [JEO04], en mentionnant seulement que la SA implique qu'il faut être prudent face à l'interprétation des résultats.

La thèse propose une utilisation beaucoup plus concrète de la SA, mais pourrait s'appliquer à toutes les situations montrées dans la littérature présentée à l'Annexe 1.

1.4 STRUCTURE DE LA THÈSE

Le chapitre 2 décrit la méthode de la SA proposée et la compare à une méthode étant très rapprochée proposée par Theiler dans [THE92]. La classification de séries non-linéaires classiques est traitée. Il est montré que la méthode proposée permet de faire la classification de ces signaux non-linéaires contrairement à la méthode de Theiler. Quoique ces travaux ont été fait pratiquement en dernier, ils sont idéaux pour montrer les principes de la SA et des caractéristiques non-linéaires utilisées.

Le chapitre 3 présente la première application sur laquelle l'utilisation de la SA a été essayée. Les raisons qui ont amenées à son utilisation en tant que caractéristique de signal sont présentées. La problématique est celle de la détection de lombalgie chronique non-spécifique par matrice de capteurs d'électromyographie de surface (sEMG).

Le chapitre 4 aborde l'interprétation des résultats de la SA sous trois angles. Pour chacun, un exemple d'interprétation original est développé pour chaque angle :

- 1) Point de vue traitement du signal : L'aspect non-aléatoire du spectre de phase,
- 2) Phénomènes physiologiques : La synchronisation de potentiels d'actions d'unités motrices,
- 3) Artéfact de la méthode : L'effet de fenêtrage.

Au chapitre 5, un autre exemple d'application est donné. La SA a montré contenir de l'information pouvant aider la reconnaissance de mouvements de la main par matrice de capteurs sEMG. On remarque aussi que l'utilisation de différentes caractéristiques non-linéaires par la SA offrent de meilleures performances.

La conclusion se trouvant au chapitre 6 souligne l'originalité de la thèse et pointe vers de nouvelles avenues ouvertes par l'utilisation de la SA en tant que caractéristique de signal.

Chapitre 2: COMPARAISON ENTRE LE SCORE PROPOSÉ ET CELUI DE THEILER

La caractéristique mise de l'avant ressemble à une valeur absolue près à une caractéristique de signal proposée par Theiler [THE91] qu'il a utilisé pour évaluer la précision du test d'hypothèse et qui n'a pas été utilisée par la suite. Les deux versions continues de la SA sont trop près l'une de l'autre pour ne pas être comparées.

Dans [CAZ20a], la complémentarité des méthodes fractales d'Higuchi et de Katz ont été montrées complémentaires théoriquement et par l'application de la SA sur des simulations de séries non-linéaires classiques. La version de la SA utilisée est celle présentée dans la thèse. Il est montré que l'utilisation des scores de SA des deux caractéristiques non-linéaires permet de classifier les trois séries non-linéaires.

On reprend dans ce chapitre la problématique de classification des trois séries en comparant le score proposé dans la thèse au score présenté par Theiler. Il est montré que l'approche de Theiler permet la détection des séries non-linéaires, mais pas leur classification. Le chapitre liste les séries non-linéaires utilisées ainsi que leurs paramètres, montre les méthodes numériques nécessaires pour obtenir les scores de SA, compare les résultats de la méthode proposée avec l'approche de Theiler et discute les implications.

2.1 SÉRIES NON-LINÉAIRES CLASSIQUES

Les trois séries non-linéaires considérées sont présentées ici. Ces séries non-linéaires sont particulièrement intéressantes que pour certaines plages de paramètres où elles ont un comportement chaotique. Les paramètres sélectionnés sont donc donnés.

2.1.1 Suite logistique

La suite logistique est reconnue comme l'équation la plus simple permettant d'obtenir une suite chaotique [MAY04]. Elle est simplement une équation parabolique à un seul paramètre.

$$x[n + 1] = rx[n](1 - x[n]) \quad (2-1)$$

Pour $r = 3.8$, le régime est chaotique.

2.1.2 Suite de Hénon

La suite de Hénon [HEN76] est généralement représentée par un système à deux équations mais une série peut être écrite sous la forme à équation unique suivante :

$$x[n + 1] = 1 - ax[n]^2 + bx[n - 1] \quad (2-2)$$

Les paramètres $a = 1.4$ et $b = 0.3$ sont utilisés pour produire une série chaotique.

2.1.3 Attracteur de Rössler

L'attracteur de Rössler [ROS76] est une des séries non-linéaire les plus simples permettant d'obtenir une série chaotique.

$$dx/dt = -y - z \quad (2-3)$$

$$dy/dt = x + ay \quad (2-4)$$

$$dz/dt = b + z(x - c) \quad (2-5)$$

C'est une version minimalist du très connu système de Lorenz [LOR63]. Contrairement aux deux suites précédentes, l'attracteur de Rössler est un processus à temps continu et doit donc être échantillonné. Une méthode de Runge-Kutta d'ordre 5 avec un pas de simulation de 0.05 secondes a été utilisée pour les simulations. Les choix liés aux simulations numériques peuvent changer drastiquement les séries chaotiques mais ne devraient pas modifier les conclusions

tirées de manière importante. Dans le pire des cas, la non-linéarité qui est détectée ou classifiée est celle causée par la méthode de résolution d'équations différentielles.

2.1.4 Bruit coloré

Afin de tester la détection et la classification contre des bruits corrélés de spectres de puissances similaires aux séries non-linéaires, des données de substitution sont générées à partir des séries non-linéaires. Les séries n'ont pas des spectres de puissance identiques. Il est montré dans [CAZ20a] que la variabilité des caractéristiques non-linéaires utilisées est beaucoup plus fortement expliquée par la différence de spectre de puissance que par la nature non-linéaire des données. Il est aussi montré que la SA permet d'éliminer la variabilité causée par le spectre de puissance. Sans répéter ces démonstrations, les séries de substitution sont tout de même utilisées à titre comparatif.

2.2 MÉTHODES NUMÉRIQUES

La section présente les méthodes numériques utilisées ainsi que leurs paramètres. La Figure 2-1 présente l'ensemble des méthodes numériques utilisées pour obtenir des scores de SA.

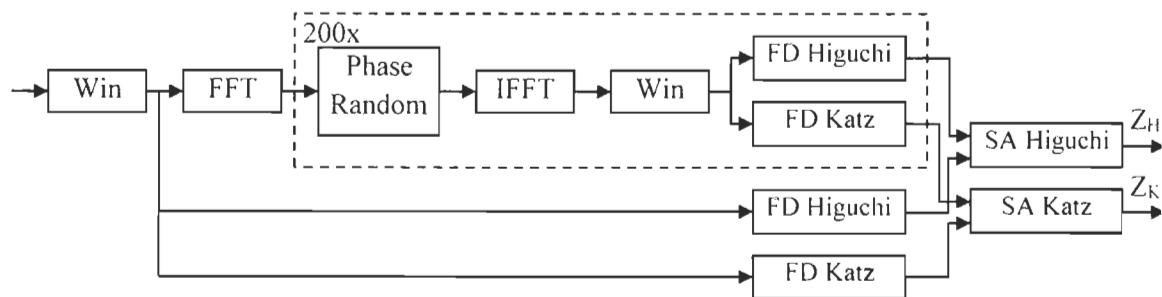


Figure 2-1 SA à deux scores et fenêtrage

2.2.1 Méthodes de SA

Bien que plusieurs hypothèses nulles existent [ThE92], la version de la SA considérée utilise l'hypothèse nulle que la caractéristique ait pu être obtenue par un processus autorégressifs et moyenne mobile (ARMA) ayant le même spectre de puissance (ou même fonction d'autocorrélation). Des séries de substitution sont générées. La caractéristique de la série originale est comparée à celles des séries de substitution. La méthode pour générer les séries de substitution et les différentes approches pour générer un score sont discutées dans ce qui suit.

2.2.1.1 Séries de substitution

Les séries de substitution créées avec contrainte sur le spectre de puissance peuvent être générées par deux méthodes [THE92] : 1) estimation d'un processus ARMA et filtrage de bruit et 2) randomisation de la phase dans le domaine de Fourier. L'Annexe 7 présente un code Matlab® pour la génération des données de substitutions.

L'estimation du processus ARMA a l'avantage d'éliminer les effets de fenêtrage. Par contre, il faut décider de la structure du processus ARMA. Même si c'est un problème résolu depuis longtemps, l'interaction entre la sélection de la structure et la SA n'est pas traité dans la littérature. Ce problème n'est pas abordé non-plus dans la thèse.

La randomisation de la phase est beaucoup plus populaire dans la littérature. Aucun paramètre n'a à être sélectionné. La méthode consiste à utiliser la transformée de Fourier (FFT) du signal, de rendre la phase aléatoire et d'appliquer la transformée de Fourier inverse (IFFT). Cependant, lorsque le nombre de données est faible, l'utilisation de fenêtrage devient nécessaire. La randomisation de la phase est utilisée dans la thèse.

2.2.1.2 Score selon Theiler

Les méthodes présentées par Theiler dans [THE92] sont toutes orientées pour offrir un test statistique vérifiant si une caractéristique non-linéaire aurait pu être observée pour un signal linéaire. L'approche privilégiée est la création d'un histogramme des caractéristiques obtenues sur des séries de substitution respectant l'hypothèse nulle. La caractéristique du signal original est simplement comparée à l'histogramme.

Par contre, une méthode continue nommée « signification » donne un score de non-linéarité. Plus ce score est élevé, plus le signal a des chances d'être de nature non-linéaire. En utilisant D , la dimension fractale, comme caractéristique non-linéaire, le score selon la méthode de Theiler est calculé ainsi :

$$Z_{Theiler} = \frac{|D - \bar{D}_S|}{\text{std}(D_S)} \quad (2-6)$$

Notons que D_S signifie la dimension fractale des séries de substitution. Le score utilise une valeur absolue. Un signe est donc perdu. Est-ce important? Pour les tests d'hypothèse proposés dans [THE92], non. Pour l'utilisation comme caractéristique par contre, il est possible que l'information contenue dans le signe soit capitale.

2.2.1.3 Score proposé

La thèse propose d'utiliser un score qui garde le signe de la différence :

$$Z = \frac{D - \bar{D}_S}{\text{std}(D_S)} \quad (2-7)$$

La seule différence avec la méthode de Theiler est le retrait de la valeur absolue.

Le calcul de la précision du score selon le nombre de séries de substitution a été développé et est montré à l'Annexe 2:. Le nombre de séries de substitution utilisées dans la présente section est de 200, pour une erreur relative d'environ 10% lorsque le score est fort (en valeur absolue).

2.2.2 Méthodes fractales

La SA nécessite une caractéristique non-linéaire pour générer un score. La dimension fractale est utilisée ici. Les méthodes fractales utilisées, soit les méthodes d'Higuchi [HIG88] et de Katz [KAT88] sont présentées ici. Bien que d'autres méthodes existent, il a été possible de montrer que celles-ci peuvent être complémentaires selon le choix de certains paramètres dans [CAZ20a]. L'Annexe 7 présente les codes Matlab® utilisés pour générer les FDs.

2.2.2.1 Higuchi

La méthode d'Higuchi [HIG88] utilise la pente de la longueur de courbe selon le taux de sous-échantillonnage en échelles logarithmiques. Particulièrement, la longueur de courbe est calculée selon l'équation suivante :

$$L_m(k) = \left\{ \left(\sum_{i=1}^{\lfloor \frac{N-m}{k} \rfloor} |u(ik + m) - u((i-1)k + m)| \right) \frac{N-1}{\lfloor \frac{N-m}{k} \rfloor \cdot k} \right\} \quad (2-8)$$

La variable k est le taux de sous-échantillonnage. L'indice m quant à lui est un décalage. Pour un certain sous-échantillonnage k , on peut partir la sommation à $k-1$ décalages. La longueur de courbe totale $L(k)$ est la sommation sur m de $L_m(k)$. Cette équation prend soin de corriger pour le nombre de données selon l'échelle avec une attention particulière aux effets de bord.

Les taux de sous-échantillonnages utilisés doivent être choisis. Souvent, une région de linéarité de $L(k)$ est utilisée. Un paramètre k_{max} est sélectionné. Si on veut suivre l'idée que la

dimension fractale représente ce qui se passe lorsque l'échelle tend vers l'infiniment petit, on peut se limiter à des taux de sous-échantillonnages faibles. C'est ce qui est fait ici où k_{max} est ajusté à une valeur de 5.

2.2.2.2 Katz

L'approche de Katz [KAT88] est basée sur la longueur de courbe totale bidimensionnelle. Or, étant donné la nature non-homogène des dimensions dont une est le temps, un facteur d'échelle doit être utilisé. Dans [CAZ20a], une discussion approfondie du facteur d'échelle est donnée.

La dimension est calculée selon :

$$D_K = \log(L_T)/\log(d) \quad (2-9)$$

où $\text{dist}(i, i + 1) = \sqrt{(u_{n+1} - u_n)^2 + \alpha^2}$ et $d = \max_j \left(\sqrt{\left(u_j - u_1 \right)^2 + \alpha^2(j-1)^2} \right)$.

Le facteur d'échelle α est ajusté à une valeur de 0.01.

2.2.3 Fenêtrage

La méthode de fenêtrage adaptée à la SA présentée au Chapitre 4.3 est utilisée. La méthode est aussi prête pour publication [CAZ20b]. L'importance de son utilisation dans le contexte présent est montrée dans [CAZ20a]. L'approche consiste à non seulement appliquer le fenêtrage aux données originales, mais aussi aux séries de substitution. L'impact est similaire pour les deux méthodes de score de SA comparés. Elle est particulièrement importante pour les séries courtes. Les séries utilisées sont très fortement non-linéaires. Elles sont donc détectées très rapidement par la SA. Aussi, pour présenter une situation intéressante où plusieurs caractéristiques sont nécessaires pour pouvoir classifier les séries, celles-ci se doivent d'être relativement courtes. La fenêtre de Tukey [BLO00] avec un paramètre ajusté à 0.05 est utilisée.

2.3 RÉSULTATS

L'utilisation de la fréquence médiane et des dimensions fractales (sans la SA) ainsi que l'impact du fenêtrage sont montrées à [CAZ20a]. Les résultats présentés se concentrent sur la comparaison du score proposé à celui de Theiler. Deux situations avec différents nombres de données sont montrées.

En premier, les résultats pour des séries de 256 données sont montrés à la Figure 2-2, comparant les résultats de la méthode proposée (a) et celle de Theiler (b). En gris pâle sont montrés les scores pour les bruits colorés composés de séries de substitution. Ces points sont équivalents à l'hypothèse nulle. Plus de détails sont expliqués dans [CAZ20a] Il est très évident que si la classification est relativement aisée avec la méthode proposée, celle de Theiler ne peut que légèrement séparer les données et impose un score positif contrairement au score proposé permettant ainsi une plus grande dispersion. Aussi, même pour le problème de détection la méthode proposée est supérieure. Les mêmes simulations sont créées pour des séries de 1024 données et montrées à la Figure 2-3.

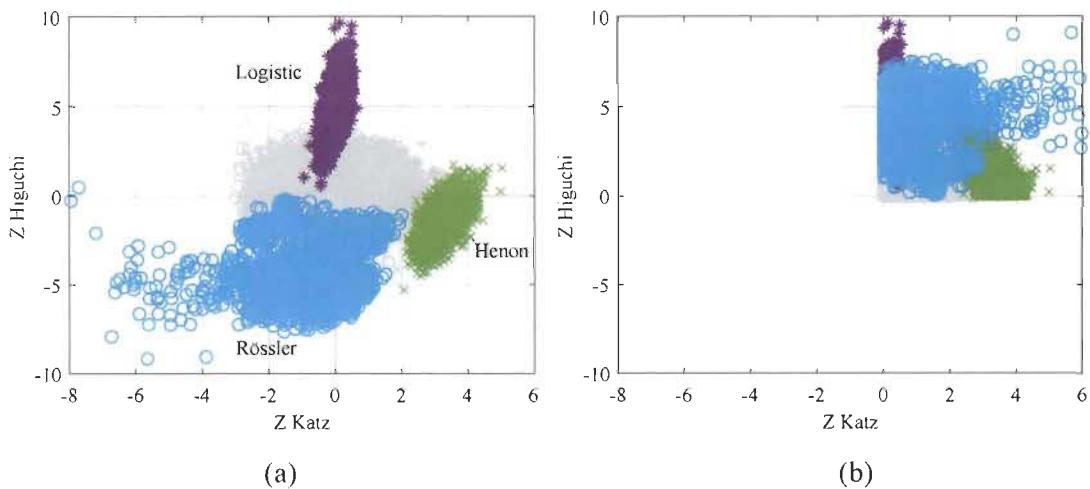


Figure 2-2 Classification de séries non-linéaires ($N = 256$) de la méthode proposée Eq. (2-7) (a) et celle de Theiler Eq. (2-6) (b)

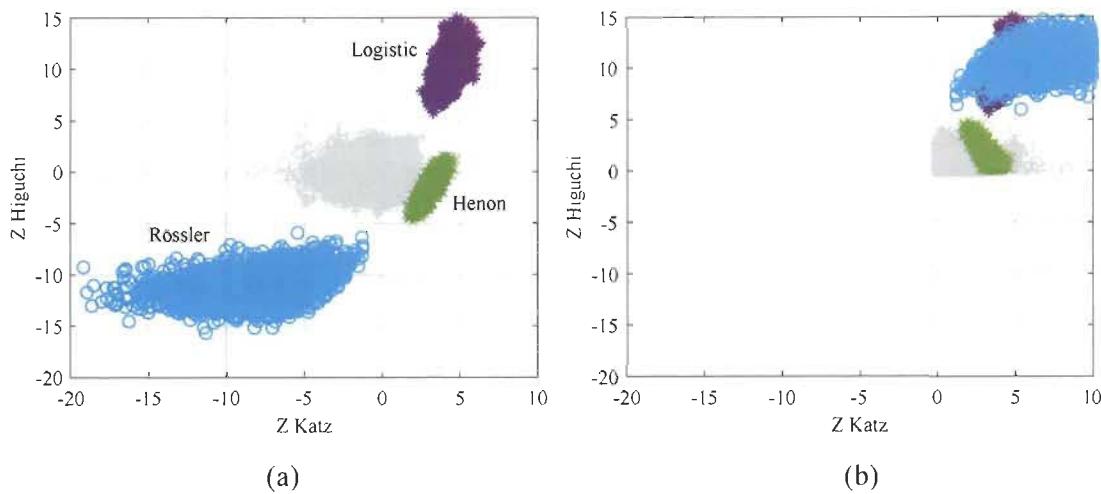


Figure 2-3 Classification de séries non-linéaires ($N = 1024$) de la méthode proposée Eq. (2-7) (a) et celle de Theiler Eq. (2-6) (b)

Encore une fois, la classification des séries non-linéaire est faisable avec la méthode proposée. Il serait même possible d'utiliser une classification linéaire. Pour la méthode de Theiler, même une méthode non-linéaire serait incapable de séparer les séries logistiques et de Rössler. Aussi, la suite d'Hénon reste difficile à détecter contre le bruit coloré.

2.4 DISCUSSION

Faire la classification complète et obtenir des taux d'erreurs n'est pas nécessaire, les comparaisons étant évidentes.

Il est clair que la méthode proposée a plus de chance de pouvoir trouver des différences entre des signaux non-linéaires. C'est particulièrement vrai si plusieurs caractéristiques sont étudiées. La méthode proposée est plus intéressante comme caractéristique pour effectuer une classification.

Chapitre 3: DÉVELOPPEMENT DE LA SA POUR LA DÉTECTION DE LOMBALGIE CHRONIQUE NON SPÉCIFIQUE

Le chapitre montre la problématique qui a amené à la conclusion que la SA est utile en tant que caractéristique de signal. L'objectif général du projet est de montrer que l'utilisation des matrices de capteurs sEMG permet d'améliorer la catégorisation du LBP. Pour ce faire, une première étape est de montrer qu'une information utile peut être extraite de ces matrices en faisant la détection de sujets LBP. Les méthodes linéaires montrent certains résultats. Pour aller plus loin, les méthodes non-linéaires semblent intéressantes. Par contre, les caractéristiques non-linéaires sont fortement corrélées aux caractéristiques linéaires. En cherchant la littérature, la seule approche traitant cet aspect est la SA, un test qui détermine si une caractéristique non-linéaire peut être expliquée par une cause plus simple que la non-linéarité, telle l'autocorrélation. C'est pourquoi la SA a été adaptée pour générer une caractéristique du signal qui est indépendant des caractéristiques linéaires.

La lombalgie chronique non spécifique est une condition ayant une forte prévalence tout en restant peu comprise. Entre autres, il n'existe actuellement aucune méthode qui permette d'effectuer la classification de sujets souffrant de lombalgie chronique non spécifique basée sur des tâches statiques. L'utilisation de matrice de capteurs sEMG (*surface Electromyography*) est une approche récente permettant d'obtenir une quantité de données impressionnante. En appliquant de telles matrices de capteurs dans la région lombaire de sujets sains et lombalgiques, on cherche à obtenir de l'information provenant directement de la région affectée. Les techniques linéaires de traitement du signal ont donné des résultats mitigés. Étant donnée la nature non-linéaire d'une grande partie des signaux de nature biologique, il est logique de

s'interroger sur la présence d'information utile dans cet aspect des données. Or, l'utilisation des aspects non-linéaires du signal EMG est limitée dans la littérature et son application à la classification de sujets lombalgiques est inexistante.

L'objectif du projet de recherche consiste à développer des caractéristiques de signaux sEMG produits lors d'une tâche statique qui permettent d'apporter une information nouvelle sur la lombalgie chronique non-spécifique. L'approche originale proposée par la thèse est d'utiliser l'analyse par données de substitution des dimensions fractales afin d'obtenir des caractéristiques discriminantes représentant la non-linéarité ou la non-stationnarité des signaux. Afin de déterminer l'intérêt des caractéristiques, elles sont testées sur le problème de classification entre des sujets sains et lombalgiques. Puisque la détection de la lombalgie par signal EMG avec une tâche statique est un problème difficile, l'utilisation de matrices de capteurs sEMG est privilégiée. La classification par réseau de neurones associé à un entraînement régulé est employée.

Des travaux effectués, deux articles ont été publiés et un autre sera soumis sous peu :

- 1) La méthode basée sur la MDF [CAZ15]
- 2) La méthode basée sur les fractales avec données de substitution n'incluant que la méthode fractale de Katz [CAZ16],
- 3) La méthode complète qui inclut la dimension fractale selon Higuchi sera soumis pour publication sous peu [CAZ20a].

Éventuellement, il serait très intéressant de voir si parmi les sujets LBP il y a des sous-catégories. Cela pourrait permettre d'enligner davantage les recherches sur le LBP. Les techniques de regroupement (*Clustering Analysis*) (CA) peuvent permettre de donner cette information. Cet

objectif long terme, qui ne fait pas partie de la thèse, donne tout intérêt de trouver des caractéristiques qui permettent la classification même si une classification parfaite était déjà accessible (ce qui n'est pas le cas). En effet, même si une certaine distance entre les groupes de contrôle et LBP permettant d'effectuer une classification supervisée est obtenue, elle n'est pas nécessairement assez grande pour permettre une classification autodidacte.

Le chapitre commence par une mise en contexte suivie d'une revue de la littérature concernant la détection du LBP par capteurs sEMG. Puis, les considérations méthodologiques ainsi que les méthodes développées sont exposées. Ensuite, les performances sont montrées. Finalement, une brève conclusion est donnée, incluant un détail des publications liées au projet.

3.1 CONTEXTE

Comprendre ce qui se passe chez des sujets souffrant de lombalgie chronique non-spécifique (LBP) à partir de capteurs est un défi qui nécessite certainement des algorithmes de traitement du signal avancé. On présente donc un projet de traitement numérique du signal qui s'inscrit dans un projet multidisciplinaire entre les départements d'Activité Physique et de Génie Électrique et Génie Informatique, faisant intervenir le Groupe de recherche sur les affections neuromusculosquelettiques (GRAN) et le Laboratoire des Signaux et Systèmes Intégrés (LSSI) du Groupe de recherche en électronique industrielle (GREI), tous deux à l'UQTR. Les travaux permettront à la fois la caractérisation et le diagnostic des problèmes lombaires et de développer de nouvelles techniques numériques pouvant s'appliquer à une vaste étendue d'applications.

3.2 REVUE DE LA LITTÉRATURE

La revue de la littérature sur les différents types de caractéristiques utilisés avec un ou plusieurs capteurs sEMG est présentée ici.

3.2.1 Caractéristiques simples, capteur unique sEMG

Un simple capteur sEMG est une source importante d'information pour plusieurs applications. Bien que cette technologie n'ait pas de place prédominante au niveau clinique, elle est toutefois au centre de plusieurs recherches. Notamment, des techniques statistiques classiques permettent d'extraire de l'information utile par rapport notamment à la fatigue musculaire [NUS08] de muscles simples. La caractérisation de la fatigue dans le bas du dos est cependant plus délicate [FAR03]. Néanmoins, une différence au niveau de groupe LBP a été démontrée [LAR02].

3.2.2 Caractéristiques avancées, capteur sEMG unique

Des techniques de traitement du signal avancé ont été aussi appliquées aux signaux sEMG. Des résultats intéressants concernant la fatigue musculaire utilisant la théorie du chaos ont été répertoriés dans [GON12]. Les fractals ont aussi été utilisés dans le même but [NUS08]. Bien que les essais n'aient pas été effectués dans la région lombaire, il est clair que ces méthodes pourraient y être appliquées. De plus [ROG13], montre que ces méthodes peuvent être appliquées en contexte multi varié. Encore, chaque méthode non-linéaire présente certains aspects des signaux. Dans le contexte de contrôle de prothèses [VIL14], plusieurs méthodes fractales ont été unies [COE14]. De plus, les différentes analyses non-linéaires sont raisonnablement interprétables physiologiquement. En effet, ces caractéristiques sont souvent liées à la cohérence et à la synchronisation de l'activité musculaire [DEL06][FAR02][SCH11]. Étonnamment, aucune analyse avec la SA pour les systèmes sEMG à un capteur, alors que pour

les systèmes EEG, ces méthodes sont courantes [HUR04][SUN12]. Ces méthodes sont particulièrement sensibles aux non-linéarités.

Pour les systèmes à un capteur, il n'y a pas dans la littérature de résultats liés à la classification des sujets LBP. L'approche multi capteurs est donc de mise.

3.2.3 Caractéristiques simples, capteurs sEMG multiples

Bien que des essais datant des années '80 aient été effectués [MAS85][MAX86][SAD83], l'approche multi canaux suscite un intérêt récent [MER03]. Beaucoup de recherche a été faite dans le but d'extraire des caractéristiques très près des unités motrices. Par ce système, on peut s'intéresser aux caractéristiques dimensionnelles des muscles, à la position plaques motrices et des unités motrices, à la vitesse de conduction ou encore à l'identification des zones d'innervations avec notamment des applications pour l'étude de la fatigue pathologique ainsi que pour les canalopathies [SWA03]. Pour ce faire, des techniques de filtrage spatial ont été étudiées [OST04]. Aussi, ces systèmes permettent dans certaines situations d'acquérir des caractéristiques des muscles telles que la vitesse de conduction musculaire [MER03] ou encore la fréquence d'activation des unités motrice. Cette dernière a notamment été reliée à la force musculaire [HOG03].

Il est vrai que ces caractéristiques sont mesurées pour des muscles relativement simples et que leur recrutement s'effectue loin de la force maximale. Pour des situations plus complexes, les approches actuelles sont insatisfaisantes [DRO06]. Ces mesures sont impraticables pour la région lombaire [FAR03].

Toutefois, par rapport aux systèmes à un seul capteur, les matrices de capteurs ont des avantages non négligeables quant à la problématique du placement d'électrodes [STA05][MES05]. De

plus, même de petites matrices ont permis l'amélioration substantielle d'un contrôle de prothèse à base de signaux myoélectriques [HUA09]. Et même pour la détection du LBP, il semble que l'approche multicanale soit la voie à suivre.

Sans que ce soit une matrice de capteur à proprement dit [DEL93] a montré qu'un ensemble de capteurs permet, avec un traitement aussi simple que la fatigue musculaire (pente de la fréquence médiane (MDF)) de permettre une certaine classification de patients LBP, quoique les résultats étaient difficilement transférables en milieu clinique. Aussi, même en l'absence de validation croisée, les travaux de [FIN03][REG03] démontrent l'intérêt de l'approche.

Nous croyons donc que les difficultés à identifier des phénomènes de bas niveau [FAR04] ne touchent pas réellement l'étude du LBP. Nous pensons que les systèmes multicanaux sont donc adaptés à une étude plus approfondie du LBP.

3.2.4 Caractéristiques avancées, capteurs sEMG multiples

Bien que plusieurs avancées aient été réalisées au niveau du traitement des signaux sEMG, leur utilisation en contexte de matrice de capteur sEMG est peu développée dans la littérature. Certains filtrages spatiaux non-linéaires ont été tentés pour améliorer la détection de décharge simple sur des matrices de 3x3 capteurs [ZHO09]. Un succès récent des méthodes fractales utilisées dans le contexte de matrice de capteurs sEMG est lié au domaine obstétrique où une classification du type de poussé est réalisée [DIA14]. Aucun travail en ce sens n'a été effectué pour la détection du LBP. Nous souhaitons donc intégrer les méthodes de traitement du signal avancées aux systèmes sEMG multicanaux basée sur la SA utilisant la dimension fractale.

3.3 MÉTHODOLOGIE

L'état de l'art actuel pourrait se résumer à dire que ce qui est présent dans la littérature pour la détection du LBP est de l'ordre des méthodes linéaires. Des méthodes dites non-linéaires ont été appliquées pour le problème de fatigue musculaire, mais pas dans la région lombaire. Aussi, les méthodes non-linéaires testées pour la fatigue musculaire restent corrélées aux méthodes linéaires [GON12].

Les méthodes linéaires avec tâche statique n'ont pas permis d'obtenir une détection lorsqu'une validation croisée était appliquée. Cependant, on laisse une chance à cette approche avec espoir que l'utilisation des matrices de capteurs permettra d'avoir suffisamment d'information pour obtenir une certaine performance au niveau de la classification et non obtenir un résultat simplement « statistiquement significatif ». On souligne en premier ce qui est à considérer pour éviter les biais méthodologiques. Ensuite, une méthode utilisant une caractéristique linéaire est décrite.

3.3.1 Tâches statiques et fenêtre fixe

Plusieurs méthodes ont été développées pour détecter les problèmes lombaires non-spécifiques. Cependant, il n'y a pas eu de résultats concluants à partir de tâches statiques pour signaux sEMG. C'est sur cet aspect que ce concentre la thèse. La tâche accomplie par les sujets était le test de Sorensen, qui cible les muscles du dos, particulièrement les muscles érecteurs du rachis (*Erector Spinae*). La tâche de Sorensen est effectuée jusqu'à épuisement complet. Cela produit des durées de tâches très variables, de 30 secondes à 2 minutes. La plage de temps est différente pour les sujets LBP et de contrôles. Cependant, c'est une information qui est triviale. Un chronomètre serait satisfaisant pour obtenir cette information. Cela n'exploite donc pas la prise

de mesure des capteurs EMG. La durée de la série de données peut affecter certaines caractéristiques. Pour s'assurer de retirer cet effet, on a fixé une fenêtre de données constante.

La publication réalisée utilisant la pente de la MDF [CAZ15] utilise la durée totale des données. Les résultats de la méthode linéaire devraient donc être encore moins forts que ce qu'on a présenté en considérant le retrait de l'effet de la durée. La décision de fixer une fenêtre de données a été prise par la suite de cette publication et le reste des travaux est réalisé avec une fenêtre de durée fixe.

3.3.2 Utilité des matrices sEMG pour l'analyse de séries temporelles

Dans la littérature, l'utilisation de capteurs uniques pour la détection du LBP a permis d'obtenir des résultats statistiquement significatifs, mais sans capacité réelle d'effectuer une classification. Ceci était fait par exemple pour une méthode linéaire, la MDF [LAR02]. Pour réellement pouvoir effectuer une certaine classification, nous avons eu besoin de la matrice de capteurs pour extraire une plus grande information.

Pour les méthodes non-linéaires, il est aussi peu probable que l'analyse du signal d'un seul capteur permette d'obtenir de meilleurs résultats « statistiquement significatifs ». Pour évaluer si une caractéristique non-linéaire est pertinente pour l'étude du LBP, il est normal de vouloir utiliser des matrices de capteurs. Dans notre cas, nous utilisons deux matrices de 5x13 capteurs.

A priori, on peut jouer à deviner où placer un capteur pour avoir le meilleur résultat aux fins de classification. Cependant, l'utilisation de matrices de capteurs permet de couvrir une grande région et à ne pas avoir à deviner le meilleur emplacement des activités musculaires. On pourrait soulever la problématique que les matrices sont de taille fixe. Or les sujets ont des tailles et silhouettes très variables. Il serait intéressant de transformer les données de sorte à obtenir

l'équivalent d'une matrice qui s'adapterait à la taille de la personne. Cependant, ceci nécessiterait de trouver l'origine des sources et donc d'avoir accès à une matrice d'impédance du corps humain dans toute la région thoracique. Ceci s'appelle de l'électromyographie assistée par ordinateur (*Computed Electromyography*). Ceci est un sujet ardu qui nécessiterait de grandes ressources. Toutefois, on sait qu'outre les questions de régularisation, les opérations nécessaires pour obtenir les signaux sources sont linéaires. Donc, en prenant les signaux au niveau des capteurs, un réseau de neurones artificiels (NN) devrait pouvoir se passer de cette inversion de modèle. Une transformation linéaire avant un NN, outre que pour des questions d'initialisation du processus d'apprentissage, ne devrait pas avoir d'impact majeur sur les résultats. Il serait par contre pertinent d'effectuer la recherche des signaux de sources aux fins d'interprétation. En effet, il est habituellement difficile d'interpréter les calculs faits par NN ou autres méthodes d'apprentissage non-linéaire.

3.3.3 Fléau de la dimensionnalité et validation croisée

Le terme de fléau de la dimensionnalité exprime le fait qu'il est délicat de résoudre des systèmes comportant plus d'inconnus que d'équations. Pour faire face à cette difficulté, des techniques de régularisation ou d'arrêt prématué (*Early Stopping*) lors de l'entraînement permettent de limiter le sur-apprentissage.

Toutefois, ces techniques nécessitent généralement de former des groupes de sujets d'entraînement, de validation et de test. Étant donné le petit nombre de sujets disponible, il n'est pas raisonnable de former ces trois groupes. On privilégiera donc une méthode de validation croisée telle l'exclusion (*Leave-One-Out*) [KOH95]. Cela permet de produire l'effet de deux groupes de données à partir d'un seul.

Pour pouvoir avoir des résultats équivalents à ce qui aurait été obtenu par trois groupes de données, il pourrait être tentant d'utiliser des validations croisées de manière imbriquée. Cependant, le temps de calcul augmente de manière exponentielle avec l'imbrication. On a plutôt considéré deux approches :

- L'utilisation de l'approche Bayésienne qui ne nécessite pas d'ajustement de paramètre arbitraire. Ceci permet de ne pas avoir besoin d'adaptation, et donc élimine le besoin d'un groupe de validation.
- L'analyse de la sensibilité aux paramètres ajustables. On peut considérer qu'un paramètre qui affecte peu les résultats a moins besoin d'être passé en validation croisée.

3.3.4 Tests multiples

Les méthodes non-linéaires ont généralement au moins un paramètre, sinon plusieurs, à ajuster, par exemple :

- Le calcul de la dimension fractale selon Katz [KAT88] nécessite une pondération entre les axes x et y lorsqu'utilisé sur des quantités inhomogènes tels le temps et la tension électrique.
- Dans le calcul de la dimension fractale selon Higuchi, le choix du taux de sous-échantillonnage maximal *a priori* arbitraire, quoiqu'il existe des méthodes pour en faire la sélection. De plus, il est habituel de ne pas inclure tous les taux intermédiaires, ce qui entraîne plus de choix.
- Pour plusieurs méthodes basées sur la théorie du chaos, une matrice embarquée des données doit être construite. Celle-ci nécessite un taux de sous-échantillonnage ainsi

qu'une profondeur. La méthode d'entropie de Pincus [PIN06] n'a pas besoin de matrice embarquée, mais nécessite tout de même un choix de profondeur ainsi qu'un horizon de prédiction.

Lorsqu'utilisés pour la détection de non-linéarité, ces choix doivent être faits avant d'appliquer une analyse par données de substitution, sans quoi l'inférence s'en trouvera biaisée.

De même, dans le cas de la classification que nous désirons effectuer, il est nécessaire d'effectuer les choix de paramètre *a priori*, surtout étant donné le nombre limité de sujets inclus dans l'étude. La même logique prévaudra pour les travaux futurs sur le CA.

3.3.5 Proposition d'une méthode linéaire

Si le projet s'intéresse aux méthodes non-linéaires, il faut pouvoir comparer quelque part les méthodes développées avec l'alternative linéaire. Or, il n'y avait pas de méthodes linéaires qui donnaient des résultats concluants pour des capteurs uniques et la littérature sur les matrices de capteurs est discutable d'un point de vue méthodologique. Donc, on a développé un point de comparaison. La possibilité de comparer les performances avec des méthodes linéaires permet aussi de répondre à la critique de la parcimonie des méthodes non-linéaires. Nous comptons ainsi pouvoir affirmer « Les méthodes linéaires donnent des résultats insatisfaisants. Il est justifié de passer aux méthodes non-linéaires vu l'amélioration apportée par cette approche». De plus, il est évident que les méthodes développées d'analyse linéaire pourraient aussi s'avérer complémentaires aux méthodes non-linéaires.

Afin de compléter la littérature en ce qui a trait aux méthodes linéaires, on a publié une méthode basée sur la MDF et l'analyse Bayésienne Naïve. Sans retranscrire la publication ici, il est utile d'expliquer que la MDF est définie comme la fréquence à laquelle la puissance des fréquences

inférieures est égale à 50% de la puissance totale. La MDF est reliée à la fatigue musculaire et lors d'une tâche de fatigue, celle-ci a tendance à descendre. Aussi, si l'analyse Bayésienne établit généralement une matrice de variance-covariance pour exprimer la distribution des caractéristiques selon la catégorie du sujet, l'approche « Naïve » considère cette matrice comme étant diagonale. Cette approximation est très robuste, particulièrement face aux violations de l'hypothèse de normalité. On présente à la figure 3-1 le système proposé pour la caractéristique linéaire. Elle inclut séquentiellement un fenêtrage, le calcul de la MDF pour chaque fenêtre, le calcul de la pente de cette fréquence dans le temps, des étapes de normalisation et de retrait de valeurs aberrantes, et finalement le calcul des probabilités et leur combinaison. Notons que la numérotation des équations est celle trouvée dans [CAZ15].

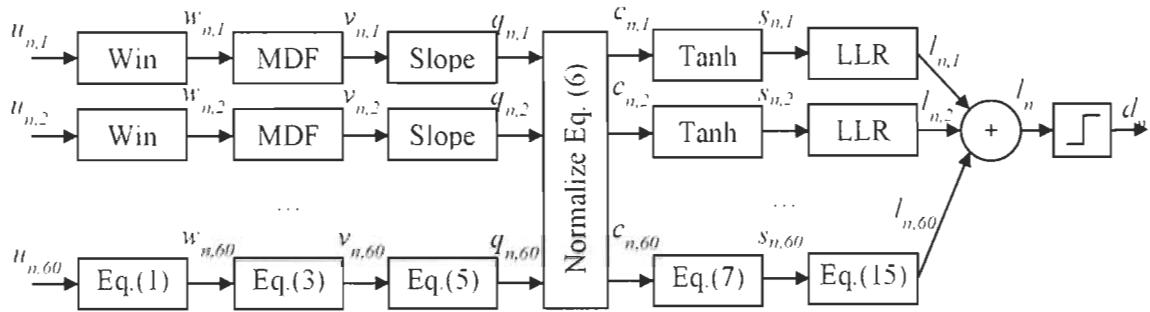


Figure 3-1 Système de classification utilisant la fréquence médiane

3.3.6 Approche non-linéaire proposée

L'utilisation de caractéristiques non-linéaires des signaux dans le but de détecter le LBP est proposée. Or, on souhaite des caractéristiques qui isolent les effets non-linéaires. C'est pourquoi la SA est considérée. Mais cette technique n'est utilisée dans la littérature que pour tester la non-linéarité d'une série. Dans notre contexte, l'utilisation de la SA pour extraire l'information non-linéaire est selon notre connaissance nouvelle. Aussi, on note que l'interprétation de la SA

comme étant strictement lié à la non-linéarité est inexacte. On discute donc premièrement de la SA, ensuite de la nouvelle application puis de son utilisation conjointement avec un NN dans le contexte de détection de patient atteint de lombalgie.

3.3.6.1 Analyse par données de substitution

La SA est présentée comme un outil qui permet de détecter qu'une série a un comportement non-linéaire [THE92]. Lorsqu'on emploie une méthode d'analyse non-linéaire telle que la dimension fractale, la dimension de corrélation ou les exposants de Lyapunov, les caractéristiques obtenues sont affectées par la simple corrélation temporelle des données. Même que cela peut être le facteur dominant. Par exemple, un signal passe-bas aura généralement une dimension fractale basse et un signal passe-haut aura une dimension fractale élevée. Il n'y a donc aucun besoin de comportement non-linéaire pour expliquer les résultats. Pour s'affranchir de l'effet de la corrélation, on peut générer plusieurs séries temporelles ayant le même spectre de puissance, mais provenant d'un processus purement aléatoire (stochastique), appliquer à ces séries la méthode non-linéaire (p. ex. dimension fractale) et obtenir une densité de probabilité de la caractéristique. On peut ensuite comparer la caractéristique de la série originale à la densité de probabilité et inférer une non-linéarité. Ceci est la procédure SA.

En d'autres mots, l'analyse de données de substitution permet de poser la question : "Est-ce que la dimension fractale observée aurait pu être obtenue par un signal stochastique (linéaire) ayant le même spectre de puissance?".

Plusieurs méthodes permettent de produire des séries répondant aux critères de l'hypothèse nulle. La méthode de la FFT (*Fast Fourier Transform*) est la plus simple. Elle consiste à effectuer la FFT, rendre la phase aléatoire et revenir dans le domaine temporel. L'utilisation de

la FFT ne nécessite pas de choix de paramètres arbitraires comme la modélisation par processus ARMA (*Autoregressive Moving Average*). Or, il faut souligner que dans les séries temporelles créées de la sorte, les signaux sont non seulement d'origine linéaire, mais aussi stationnaire. Il est plausible de dire que SA détecte non seulement les non-linéarités, mais aussi les non-stationnarités, sans faire de nuances entre les deux. Notons que certaines non-stationnarités au niveau de la variance peuvent être tenues en compte dans certaines méthodes si les variations sont lentes. Mais des non-stationnarités plus exotiques ne sont pas traitées dans la littérature.

Mentionnons que dans la littérature une grande partie de l'usage de la dimension fractale ne fait pas usage de la SA. En effet, la dimension fractale offre en une seule valeur une caractérisation générale de la complexité du signal. Étant fortement affectée par la corrélation, elle résume bien celle-ci. De plus, elle est de très faible complexité, ne nécessitant souvent que des additions, valeurs absolues et une inversion de matrice de faible dimension. Donc, bien que ce soit une fonction non-linéaire, c'est en grande partie les effets de corrélation qui sont l'intérêt de la dimension fractale lorsqu'elle est utilisée sans données de substitution.

Finalement, la façon dont on emploie la méthode SA nécessite de porter une attention particulière au nombre de séries de substitution générées. En Annexe 2:, on montre la relation entre le nombre de séries et la précision. On obtient que pour 200 séries, on a approximativement de 10% d'incertitude sur les valeurs élevées de scores Z.

3.3.6.2 Caractérisation de signaux par données de substitution

La SA est appliquée dans la littérature que pour affirmer la présence de non-linéarité. Ce qu'on propose, c'est d'utiliser les résultats d'analyse comme caractéristique des signaux. En tenant compte de la moyenne et déviation standard de la distribution des caractéristiques des séries de

substitution, on peut exprimer la non-linéarité sous forme de distance à la moyenne en unité de déviation standard. Ceci peut se comprendre comme un "score", similairement à ce qui est fait lorsqu'un test d'hypothèse sur la moyenne est effectué. On appelle donc la caractéristique du SA : le score Z.

En résumé, le score Z se calcul selon la procédure suivante, en considérant la dimension fractale :

- Calcul de la dimension fractale de la série originale
- Production de séries de substitution par la méthode de randomisation de la phase dans le domaine de Fourier
- Pour chaque série de substitution, on calcule la dimension fractale
- On calcule la moyenne et la déviation standard de la dimension fractale des séries de substitution
- La distance à la moyenne en unité de déviations standards est calculée.

3.3.6.3 Méthode de classification proposée

Une méthode plus évoluée de classification que celles proposées dans la littérature a été développée et publiée. C'est la version la plus complète actuellement qui est présentée dans cette section. La méthode est présentée dans [CAZ20a].

Le système utilise les scores Z des méthodes de dimension fractale d'Higuchi et de Katz, décrites en annexe. Pour chaque méthode, un certain nombre de valeurs extrêmes, considérées comme intéressantes sont conservées et utilisées comme caractéristiques discriminantes en entrée d'un NN. Le NN sert de méthode de classification.

Les scores Z sont obtenus par comparaison de la dimension fractale de la série originale avec les scores des séries de substitution. Ici, dans le but d'obtenir la distribution des dimensions fractales des séries de substitution, 200 séries de substitution sont produites. Chaque série est utilisée pour calculer les dimensions fractales selon les deux méthodes (Higuchi et Katz). Cela réduit le temps de calcul des séries de substitution (voir la figure 3-2).

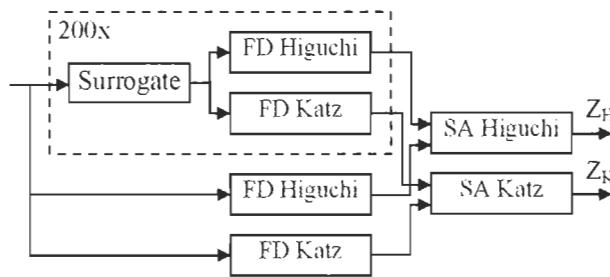


Figure 3-2 Analyse par données de substitution

Pour chaque canal, après une étape de retrait d'interférence, telle que discuter en annexe, et de fenêtrage (rectangulaire jusqu'ici), la méthode SA est appliquée. Puis, les scores obtenus sont ordonnés pour chaque matrice de capteurs (de chaque sujet). Pour chaque matrice, une sélection de N_H scores Z_H selon Higuchi et de N_K scores Z_K selon Katz avec les valeurs les plus basses sont effectuées.

Les scores sélectionnés des deux matrices sont utilisés comme entrée d'un réseau neuronal (NN) en aval (*Feed-Forward NN*). La figure 3-3 représente les connexions des entrées à un neurone de la couche cachée.

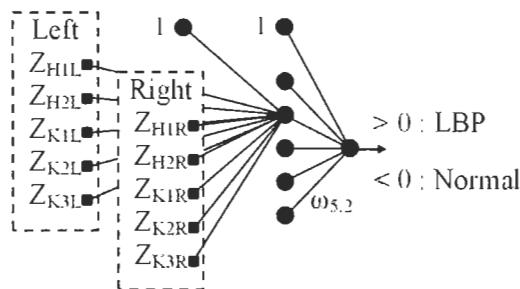


Figure 3-3 Connectivité des entrées du réseau de neurones

Pour ce qui est de l'entraînement du NN, les détails sont laissés dans la publication [CAZ16].

C'est la même approche qui est utilisée pour le système complet. L'aspect important à mentionner est l'emploi de la régulation. Cela permet de fixer le nombre d'itérations d'adaptation en offrant un bon contrôle sur la généralisation. On a effectué un balayage du paramètre de régulation pour observer son effet.

3.3.7 Procédure expérimentale

Les données traitées proviennent d'expérimentations réalisées par le laboratoire GRAN, de l'UQTR. Les données principales ont été obtenues par l'application de deux matrices de 5x13 capteurs sEMG (12.5mm IED, OT Bioelettronica, Italie) au muscle *erector spinae*, dans le but d'étudier leurs stratégies neuromusculaires lors d'une tâche d'endurance. Les sujets participants ont effectué une tâche de Sorensen à 30% de leur capacité (étalonnée au départ). Cette tâche a été accomplie jusqu'à épuisement total. Une rétroaction visuelle de la force appliquée était fournie au participant. Un groupe de sujets sains ($n = 22$) et un groupe de sujets cLBP ($n = 45$), ayant souffert de cette affection au moins 50% du temps au cours des 6 derniers mois, ou ayant eu plusieurs épisodes au cours des 12 derniers mois.

3.4 RÉSULTATS

Cette section présente dans un premier temps les relations entre différentes caractéristiques des signaux sEMG. L'objectif est de justifier l'utilisation de la SA pour se différencier des méthodes linéaires. Dans un second temps, les performances des méthodes linéaires et non-linéaires développées sont montrées.

3.4.1 Comparaison des caractéristiques

Dans cette section, on montre la relation entre la MDF, la dimension fractale et le score Z. On inclut aussi certaines relations entre les pentes de ces caractéristiques. Les graphiques sont produits en utilisant tous les canaux de tous les sujets et en comparant deux caractéristiques à la fois. Les séries sont présentées pour les groupes séparément.

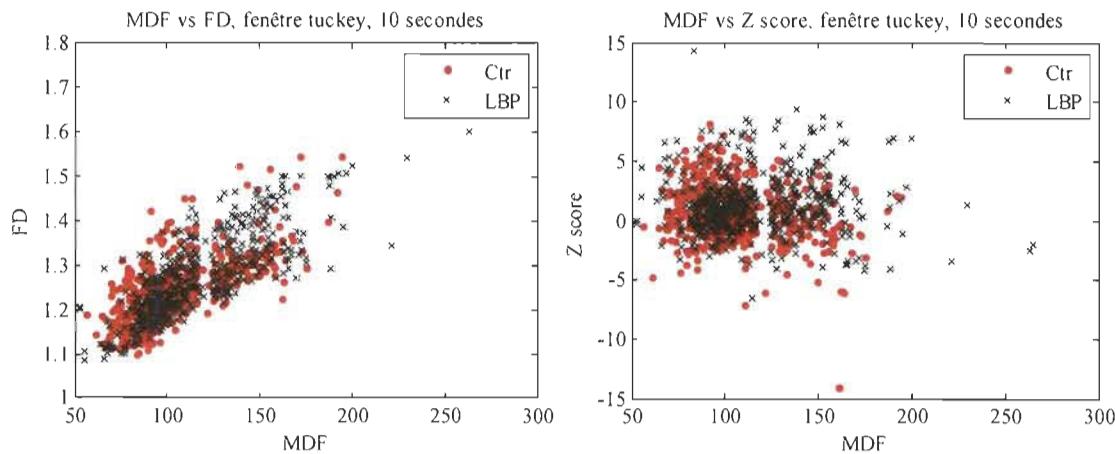


Figure 3-4 Relation entre les caractéristiques linéaires et non-linéaires

La figure 3-4 présente les résultats pour la méthode linéaire et non-linéaire (SA) pour tous les capteurs pour une fenêtre de 10 secondes pour les données de contrôle et LBP. On observe que la dimension fractale et la MDF sont fortement corrélées. Il n'est pas intéressant d'utiliser des méthodes non-linéaires qui soient fortement affectées par des effets linéaires. Ce n'est pas le cas entre le score Z et la MDF. Les points ne sont vraiment pas clairement séparés entre les groupes contrôle et LBP. Les résultats sont similaires lorsqu'on considère les pentes des caractéristiques.

La figure 3-5 présente la relation entre les pentes (temporelles sur une fenêtre de 1 seconde) de la MDF et du score Z. Il est surprenant d'observer des pentes de MDF positive. Le résultat attendu d'une tâche de fatigue est un abaissement de la MDF. Or, les pentes sont seulement statistiquement négatives. L'interprétation de la positivité d'une partie non négligeable des

pentes de la MDF reste à faire. On montre ensuite à la figure 3-6 que le score Z et la pente de la MDF ne sont pas reliés directement. Encore une fois, on n'observe pas de classification simple possible.

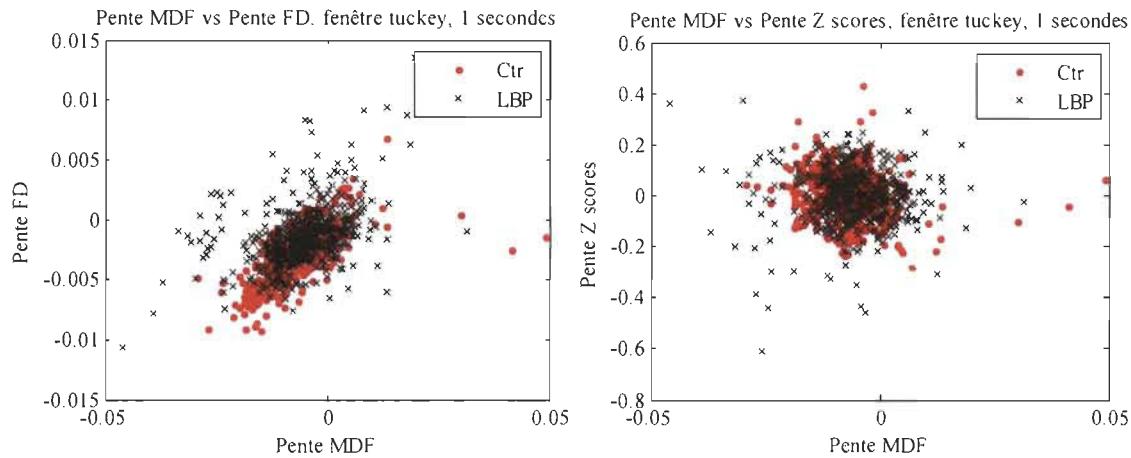


Figure 3-5 Relation entre les pentes des caractéristiques linéaires et non-linéaires

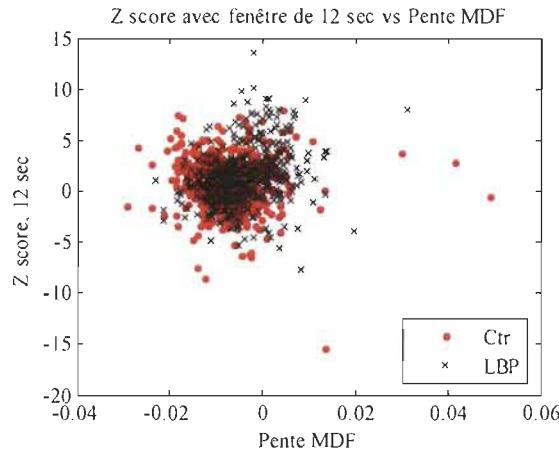


Figure 3-6 Relation entre la dimension fractale et la pente de la fréquence médiane

On montre maintenant au Tableau 3-1 le récapitulatif des corrélations entre différentes variables. On montre les résultats sans (Rect) et avec (Tukey) techniques de fenêtrage. On compare aussi l'utilisation de fenêtres de 1 et 10 secondes (il y a 10 fois plus de caractéristiques comparées pour les fenêtres d'une seconde). Les pentes sont calculées sur 10 fenêtres d'une seconde. En dernier lieu, on compare la pente de la MDF avec le score Z calculé sur 10 secondes.

Il est encore une fois clair que la MDF et la dimension fractale sont très corrélées et que cette dernière ne cible pas clairement une nouvelle source d'information, que ce soit au niveau de la caractéristique directe ou de la pente. Cependant, la corrélation entre la MDF et le score Z est nulle. La nouvelle source d'information est donc bien isolée. On note que l'application du fenêtrage n'a pas d'impact sur les corrélations. Aussi, la durée de la fenêtre influence peu les résultats.

Tableau 3-1 Corrélation entre différentes caractéristiques

x	y	1 sec Rect	1 sec Tukey	10 sec Rect	10 sec Tukey
MDF	FD	0,75	0,75	0,76	0,76
MDF	Z scores	0,08	-0,03	-0,04	-0,07
Pente MDF	Pente FD	0,49	0,53		
Pente MDF	Pente Z	-0,14	-0,08		
Pente MDF	Z scores 10s	0,15	0,15		

De ces résultats, on conclut deux choses : (i) la SA permet d'isoler une nouvelle source d'information et (ii) il n'y a pas de méthodes de séparation des groupes simples qui peuvent être appliquées.

3.4.2 Principaux résultats de classification

Cette section présente les résultats de classification obtenus avec l'utilisation des caractéristiques linéaires et non-linéaires étudiées.

3.4.2.1 Méthode linéaire

Premièrement, les résultats de la classification à partir de la MDF sont montrés dans le tableau 3-2. Ce tableau compare les performances (taux d'erreur) sur les données d'entraînement et de validation croisée. Ensuite, on affiche la valeur p, à savoir la probabilité

que ce taux d'erreur ait été atteint par hasard (test unilatéral). Il faut mentionner qu'avec la méthode Bayésienne Naïve, aucun paramètre arbitraire n'est nécessaire. Le fait que les performances des données d'entraînement et de validation soient relativement similaires montre que la généralisation se contrôle naturellement par la méthode. Toutefois, on ne voit pas de gain par l'utilisation de l'information des deux matrices gauche et droite de la colonne vertébrale.

Tableau 3-2 Taux d'erreur de la méthode linéaire proposée basée sur la fréquence médiane.

	MCR (%) Train Data	MCR (%) Validation	p-Value
LBP Left	26	35	0,43
Control Left	14	27	0,013
Mean Left	20	31	0,0093
LBP Right	28	33	0,30
Control Right	18	36	0,08
Mean Right	23	34	0,0345

3.4.2.2 Méthodes non-linéaires

Les figures 3-7 montrent les performances (taux de succès) du système utilisant l'analyse par substitution de données, basées sur les méthodes de Katz et Higuchi, individuellement (a) et conjointement (b). Les résultats pour différents nombres de scores retenus pour chaque méthode allant de 1 à 10 sont inclus. Individuellement, les méthodes de dimension fractale de Katz et d'Higuchi vont chercher environ 80 et 90% de succès. Ensemble, il est possible de dépasser les 95%. Bien que le nombre de sujets utilisés ne permette d'affirmer que la différence entre les méthodes n'est pas liée à une variation due au hasard, cela laisse tout de même entrevoir une certaine complémentarité entre l'information obtenue par les deux méthodes non-linéaires.

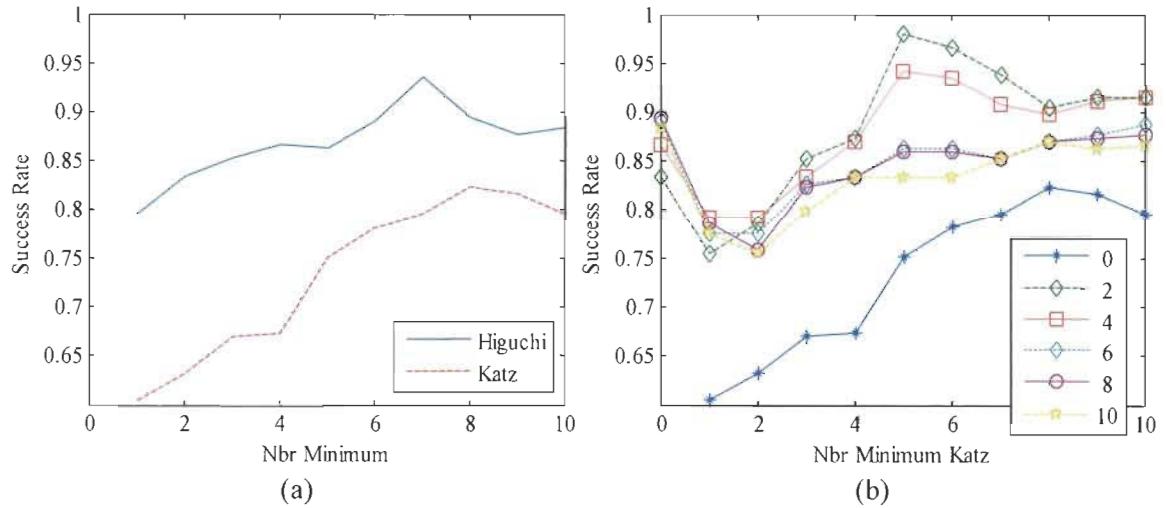


Figure 3-7 Performances de la méthode basée sur l'analyse par données de substitution basées sur les méthodes de Katz et Higuchi, individuellement (a) et conjointement (b).

La figure 3-8 montre l’effet de la variation du paramètre de régulation Gamma (paramètre qui contrôle la parcimonie du système en pondérant les performances et l’amplitude des poids du réseau de neurones) pour différents ensembles de caractéristiques autour de $Z_H = 2$ et $Z_K = 5$. L’impact de Gamma est relativement constant autour de l’optimum, laissant supposer que la bonne généralisation est robuste au choix de ce paramètre. La même réflexion peut être faite pour le choix du nombre de caractéristiques.

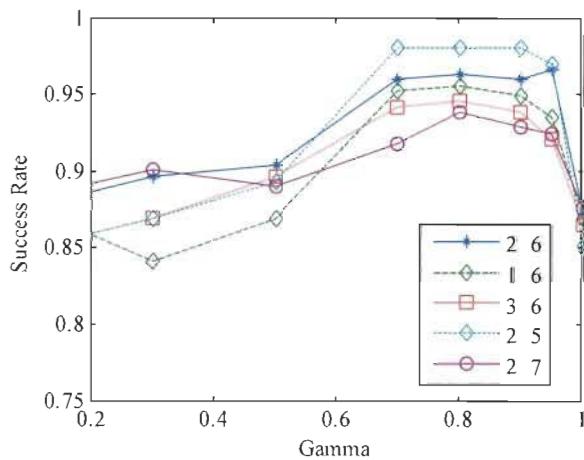


Figure 3-8 Impact du taux de régulation sur les performances du réseau de neurones

Des graphiques similaires ont été produits sur les données d'entraînement, mais pour la plupart des taux de régulation et d'ensemble de caractéristiques, la classification était parfaite. C'est normal quand on considère le nombre de variables disponibles.

Il faut admettre que les données utilisées pour l'entraînement du système non-linéaire sont un sous-groupe des données utilisées pour l'utilisation de la MDF. On a décidé entre les deux essais de conserver des données pour une classification autodidacte (*Cluster Analysis*) éventuelle. Aussi, ce ne sont pas les mêmes méthodes de classification qui ont été utilisées pour les différentes caractéristiques linéaires et non-linéaires. En effet, l'utilisation de méthodes non-linéaires permet de faire une sélection basée sur les valeurs extrêmes, ce qui permet de réduire largement la dimensionnalité du système. Il y avait un avantage au niveau d'apprentissage personnel de pouvoir travailler avec plusieurs méthodes de classification. Les résultats présentés ne donnent pas l'information à savoir quelle approche est meilleure pour effectuer la classification. Autrement dit, les résultats répondent à la question : « Quelles performances a-t-on été capable d'obtenir par les méthodes employées? » et non : « Quelles caractéristiques permettent de mieux prédire le LBP. » On peut remarquer toutefois que les méthodes non-linéaires ont donné de meilleurs résultats jusqu'à présent.

L'utilisation conjointe des méthodes linéaires et non-linéaires n'a pas été réalisée. Même si c'était une approche à considérer, il faudrait beaucoup plus de sujets pour observer un gain quelconque étant donné que les méthodes non-linéaires fonctionnent déjà bien.

3.5 CONCLUSION ET CONTRIBUTIONS

Les travaux montrés dans ce chapitre ont montré qu'il est possible et utile d'extraire l'information non-linéaire des signaux sEMG matriciels. Bien que les méthodes non-linéaires

aient offert de meilleures performances que les méthodes linéaires dans nos travaux, les deux approches pourraient se montrer complémentaires. Plus précisément, les contributions incluent :

- 1) *Utilisation de l'analyse par données de substitution (Surrogate Analysis) pour extraire des caractéristiques* : La SA est utilisée dans la littérature pour détecter la non-linéarité présente dans une série temporelle. Cependant, elle n'est pas utilisée dans le but d'effectuer d'autres types de classification. Aussi, elle n'est utilisée qu'avec des tests d'hypothèse ne permettant pas de quantifier le degré de non-linéarité. Ce qui est proposé est d'utiliser l'information contenue dans la SA pour caractériser le niveau de non-linéarité et d'utiliser cette caractéristique comme variable discriminante. Cette caractéristique est appelée score Z et elle a été expliquée à la section 3.2.
- 2) *Complémentarité entre deux méthodes d'analyse fractale* : Deux méthodes de calculs de la dimension fractale ont été étudiées, soit les méthodes de Katz [KAT88] et d'Higuchi [HIG88]. Ces deux méthodes sont basées sur différents aspects de la théorie associée aux fractales. On montre que ces méthodes donnent des résultats complémentaires du point de vue classification dans le cadre de la SA. Aussi, une analyse théorique de la relation entre les deux méthodes est offerte dans [CAZ20a].
- 3) *Avantage de la méthode Bayésienne Naïve pour la classification avec petit nombre de sujets* : Nous avons publié un article mettant en valeur la méthode Bayésienne comme algorithme de classification ne produisant pas de surapprentissage [CAZ15] et est donc approprié pour la classification avec un grand nombre de capteurs et un petit nombre de sujets.
- 4) *Entraînement et validation du réseau de neurones pour des groupes avec des petits nombres de sujets* : L'ajustement d'un réseau de neurones (NN) nécessite généralement

l’usage de 3 groupes de données, soit un pour l’entraînement, un pour la validation et un dernier pour les tests de performance. Pour un petit nombre de sujets disponible, il n’est pas possible d’avoir des groupes de tailles suffisantes. On a donc développé une approche permettant d’entraîner le réseau et d’obtenir un estimé des performances raisonnables dans ce contexte [CAZ16].

La SA est un sujet de recherche intéressant, mais encore marginal. La capacité à effectuer une classification de la manière que nous proposons va clairement dans la direction de promouvoir cette méthode. Le fait d’avoir produit une classification permet de justifier le développement théorique du score Z ainsi que l’essai de variations de la méthode. La contribution principale de ce chapitre est donc la mise en valeur de la SA.

Chapitre 4: NOUVELLES INTERPRÉTATIONS DE LA SA

L'objectif du chapitre est d'améliorer les connaissances de l'interprétation de la SA. La SA donne un chiffre, ce chiffre contient une information parce qu'il permet une certaine classification, mais que veux dire ce chiffre?

Vu l'utilisation courante de la SA se limitant à valider qu'une caractéristique non-linéaire observée n'est pas simplement explicable par une cause plus banale tel une autocorrélation du signal, le résultat de la SA est généralement interprété du point de vue de la caractéristique utilisée. Pour une caractéristique provenant de la théorie du chaos telle une dimension de corrélation, l'interprétation sera par exemple que les données montrent la présence d'un attracteur de basse dimensionnalité. Dans le cadre de la thèse, étant donné que la FD est utilisée, il serait tentant de simplement déduire (probablement à tort) pour tout résultat positif de la SA que les données contiennent une structure autosimilaire ou que le niveau d'autosimilarité différentie les sujets souffrant de lombalgie chronique de sujets sains.

À cette approche habituelle, la thèse rajoute deux autres angles d'approche : un point de vue des données de substitution et un point de vue physiologique. On peut aussi identifier les artéfacts de calcul comme une autre catégorie d'interprétations. On a donc quatre points de vue pour interpréter la SA découlant de :

- (1) la caractéristique utilisée, (le point de vue habituellement utilisé)
- (2) la méthode pour générer les données de substitution,
- (3) la cause physiologique, et
- (4) la présence d'artéfacts de calcul.

Ils ne sont pas nécessairement mutuellement exclusifs. Les points de vue s'entrecoupent. Par exemple, le complexe QRS de l'ECG est présenté comme un signal ayant un spectre de phase non-aléatoire, du point de vue (2) mais pourrait être considéré comme une somme de signaux hautement synchronisés, similaire à la synchronisation des potentiels d'actions discutés sous l'angle du point de vue (3). Trois exemples différents sont donnés dans la suite du chapitre mettant en relief les points de vue (2), (3) et (4). Au-delà des méthodes et résultats obtenus, les travaux montrent plus fondamentalement une structure pour approcher la problématique de l'interprétation de la SA.

Pour l'approche basée sur les données de substitution (2), le fait que le spectre de phase est rendu aléatoire implique que la SA détecte les spectres de phases qui ne sont pas aléatoires.

Pour l'approche basée sur la cause physiologique (3), un modèle simpliste d'unité motrice générant une certaine quantité de potentiels d'actions où la vitesse de conduction et la synchronisation peuvent être ajustées est étudié. On constate l'impact de ces paramètres de modèles sur la SA.

Finalement, pour l'analyse des artéfacts, on améliore la compréhension du biais causé par le fenêtrage sur la SA. D'autres aspects tels l'effet de quantification, les sources d'interférences et la non-stationnarité auraient pu être approfondis, mais le problème de fenêtrage était plus important pour le reste des travaux de la thèse où des fenêtres de données très limitées devaient être analysées. Quoique ce problème ait déjà été abordé dans la littérature, il est montré qu'une importante erreur résiduelle restait.

4.1 SPECTRE DE LA PHASE NON-ALÉATOIRE

Cette section résume et étend les travaux publiés [CAZ19]. L'idée originale de cette section était principalement didactique. Le but était de trouver une expérimentation permettant de bien illustrer le fonctionnement de la SA. L'idée est de comparer des signaux faciles à comprendre dont le spectre de puissance est similaire, mais dont les résultats de la SA sont différents. Or, faisant cela, il est devenu évident que de possibles applications se présentaient.

La comparaison de l'impulsion de Dirac et du bruit blanc a été le premier exemple. C'est le plus simple, surtout pour n'importe qui qui a des bases en traitement du signal. Cependant, des méthodes basées sur la distribution des données indépendantes de toutes relations temporelles permettent de différentier aisément les deux. C'est pourquoi une autre courbe a été développée dans le but d'être « invisible » aux méthodes basées sur les distributions. La détection de cette courbe est faite dans un bruit coloré de même spectre de puissance. Il a été noté que la phase de la courbe développée était parfaitement linéaire. On conclut donc que la SA est capable de détecter la linéarité de la phase

La courbe a été utilisée comme forme d'impulsion pour un signal aléatoire de type modulation par changement de phase, ou plus couramment nommé en anglais «*Binary Phase-Shift Keying*» (BPSK) de longueur de 8 bits. La SA a pu détecter ce signal dans un bruit coloré de même spectre de puissance avec une phase plus complexe. On peut donc conclure que cette méthode pourrait trouver une certaine utilité en télécommunication pour le problème de détection du spectre (*spectrum sensing*) [KUM17].

La forme de la courbe montre aussi une certaine ressemblance avec le signal d'électrocardiogramme (ECG). La SA a pu être utilisée pour détecter un signal ECG dans un

fort bruit. Ceci pourrait avoir des applications dans des contextes où la qualité de la connectivité des capteurs n'est pas assurée. Aussi, il a été montré que l'estimation du rythme cardiaque pourrait être calculé à partir de l'évolution temporelle de scores de la SA.

Notons que la capacité à détecter le ECG peut influencer l'interprétation des résultats obtenus précédemment pour la détection du LBP. En effet, il se peut que le rythme cardiaque de sujets qui ont une douleur soit différent des sujets sains. Des résidus de signaux ECG peuvent donc possiblement biaiser les résultats.

4.1.1 Dirac versus bruit blanc

Pour bien comprendre la SA, il est proposé ici de considérer la différence entre l'impulsion de Dirac et le bruit blanc. Les deux ont un spectre de puissance blanc, mais les deux sont fortement différents. Au niveau de la distribution des données, le bruit blanc est évidemment distribué selon une Gaussienne. Du côté de l'impulsion de Dirac, c'est théoriquement un nombre infini de zéros, et une valeur à un (ou autre valeur s'il y a une mise à l'échelle). Côté fréquentiel, le spectre de la phase de l'impulsion de Dirac sera constant, ou à phase linéaire selon le décalage, tandis que celui du bruit blanc sera aléatoire.

Pour générer le bruit blanc, deux approches seront utilisées. D'un côté, générateur de nombre aléatoire donnant simplement des valeurs aléatoires indépendantes distribuées normalement (*randn* dans le logiciel Matlab), et de l'autre, des données de substitution seront générées à partir de l'impulsion de Dirac. Le spectre de puissance du générateur est statistiquement d'amplitude unitaire. De son côté le bruit fait par données de substitution conserve le spectre constant de l'impulsion de Dirac. Il n'y a pas de problèmes de fenêtrage lorsqu'un bruit blanc est échantillonné pour un nombre limité de données. De plus, pour le bruit par données de

substitution, l'extension périodique ne crée pas de discontinuités. Dans les figures 4-1 et 4-2, l'impulsion et les deux formes de bruit sont illustrés.

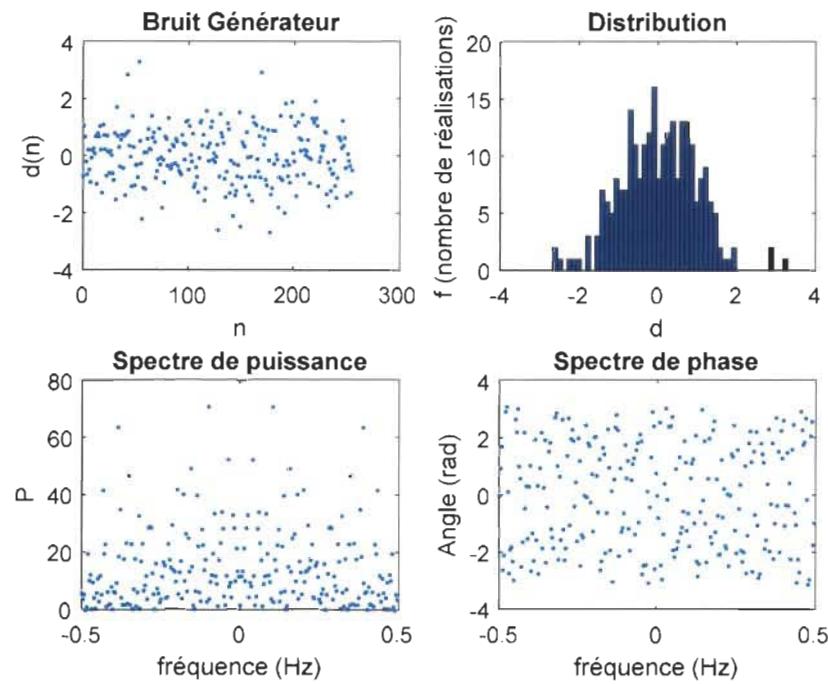


Figure 4-1 Bruit blanc, distribution, spectre de puissance et spectre de phase.

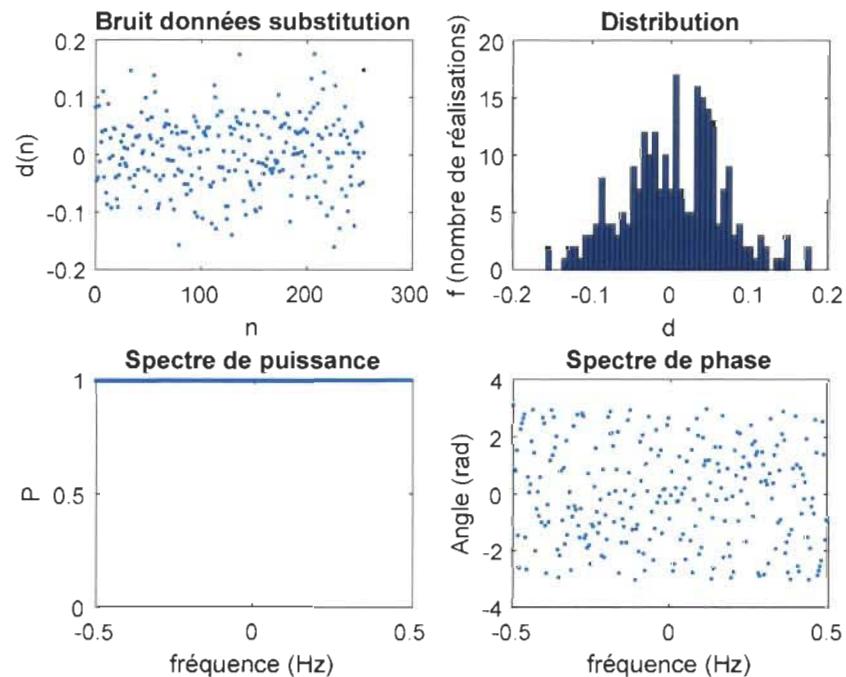


Figure 4-2 Randomisation de la phase d'impulsion de Dirac, distribution, spectre de puissance et spectre de phase.

4.1.1.1 Détection du Dirac dans un bruit blanc

On évalue maintenant les performances des méthodes de SA basées sur les FDs pour détecter l'impulsion de Dirac dans un bruit blanc (figures 4-3 à 4-6). Le bruit peut être généré de plusieurs manières, l'utilisation des données de substitution a été choisie. L'idée est de voir que la SA détecte la différence de synchronisation de la phase et est indépendante du spectre de données. Le bruit blanc créé n'est pas nécessairement Gaussien à priori. Cependant, les valeurs obtenues à très bas SNR des tests de normalité utilisés montrent que l'hypothèse gaussienne du bruit généré par données de substitution est raisonnable. Notons que le SNR en présence d'un impulsion dans un bruit est généralement mal défini, étant donné la nature de signal à énergie de l'impulsion et de signal de puissance.

Puisque ces méthodes seront utilisées plus tard, la SA est comparée aux tests de normalité de Kolmogorov-Smirnov (KS) et Shapiro-Wilk (SW). Dans le cas de l'impulsion de Dirac, les tests de normalité montrent des performances équivalentes à l'impact d'une donnée aberrante. Aussi, on comparera avec une détection par seuil.

Il sera conclu que la méthode par la SA donne des résultats moins bons que le seuil et SW. Par contre, il est clair que la SA est sensible à la présence de pic. Ceci peut parfois être négatif puisque cela signifie que la SA est sensible aux données aberrantes.

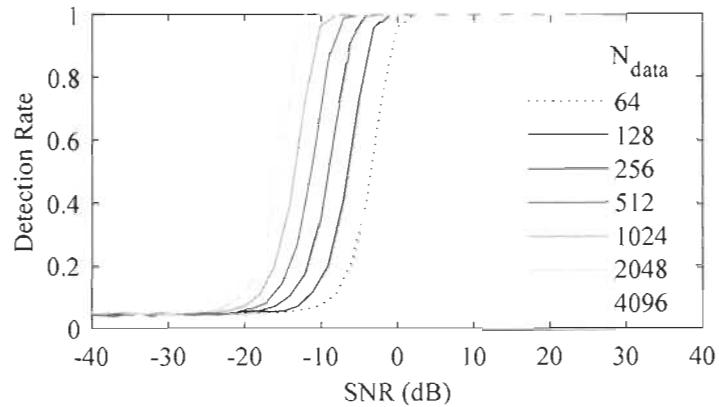


Figure 4-3 Détection du Dirac par SA basée sur Katz

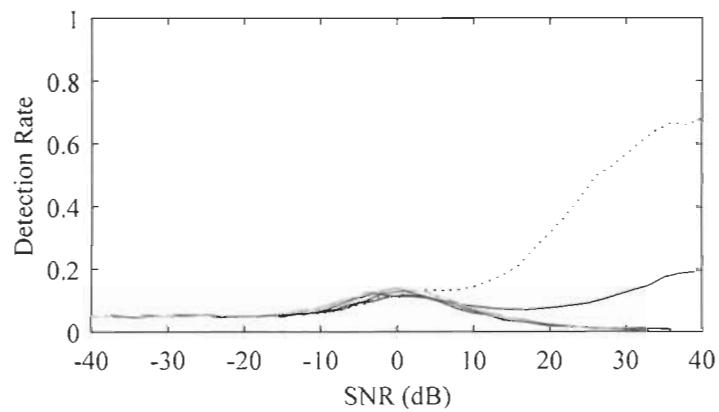


Figure 4-4 Détection du Dirac par SA basée sur Higuchi

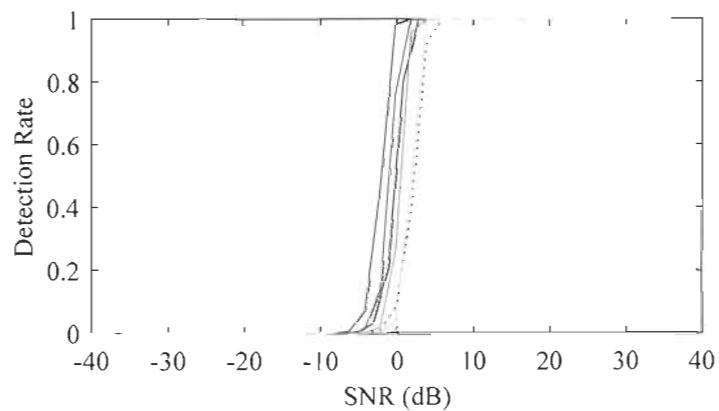


Figure 4-5 Détection du Dirac par Kolmogorov-Smirnov

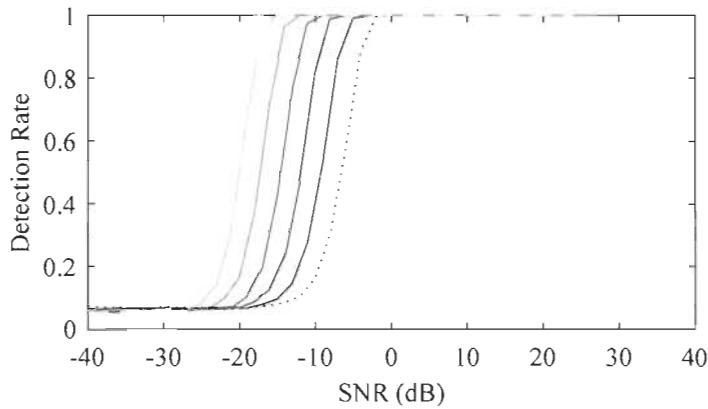


Figure 4-6 Détection du Dirac par Shapiro-Wilk

La détection de l’impulsion de Dirac par ces méthodes ne bat pas le simple seuil. En acceptant un taux d’erreur de 5% et supposant une distribution normale centrée réduite, le seuil peut être calculé à partir d’un équivalent de la correction de Bonferroni [DUN61]. Une comparaison avec méthode de Monte Carlo est donnée à la Figure 4-7 et un équivalent en termes de SNR tenant compte du nombre de données à la Figure 4-8.

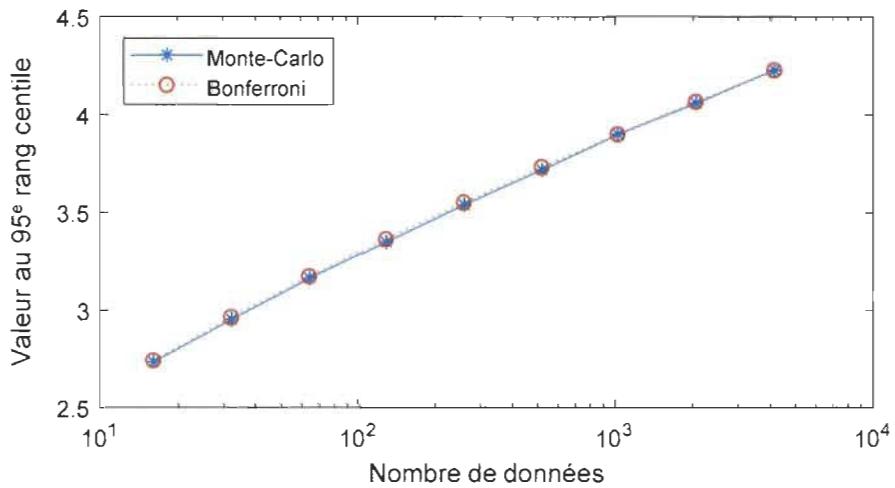


Figure 4-7 Détection du Dirac par seuil, Bonferroni et Monte Carlo

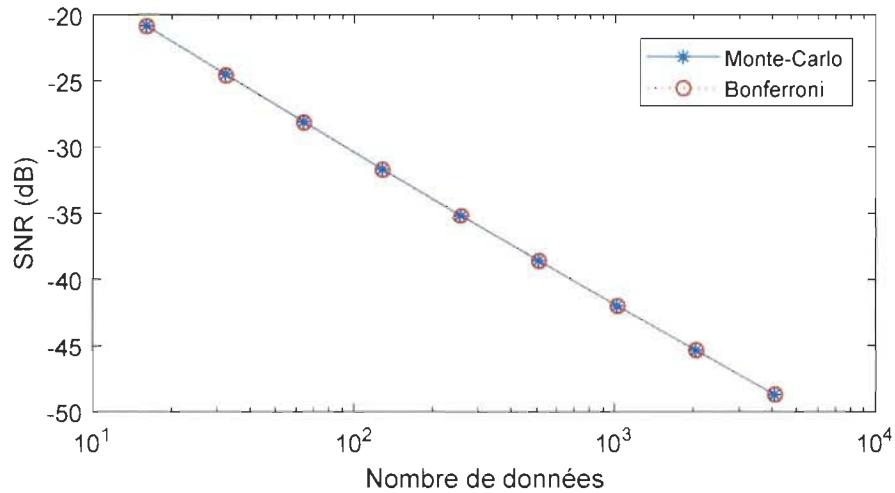


Figure 4-8 Détection du Dirac par seuil, SNR pour taux de succès de 50%

Le taux de succès de détection selon le SNR et le nombre de données avec les seuils trouvés est montré à la Figure 4-8. Les résultats sont similaires à ceux du test de normalité de Shapiro-Wilk. Par contre, ceci est considérant un test unilatéral. Les méthodes présentées avant sont bilatéral. La Figure 4-9 présente aussi les mêmes résultats pour un test bilatéral, avec les courbes pointillées. La différence est minime, environs 0.5 dB.

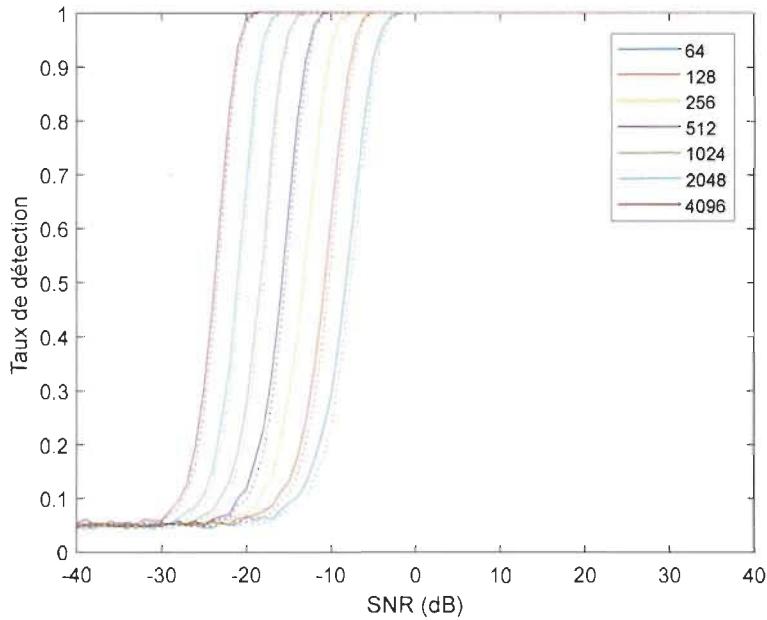


Figure 4-9 Détection du Dirac par seuil, comparaison du test unilatéral et bilatéral

La Figure 4-10 présente pour chaque longueur de données le SNR tel que le taux de détection est de 50%. (L'abréviation « Thresh » y signifie « *Threshold* », soit un seuil. Rappelons aussi KS et SW sont deux tests de normalité.) Ce choix facilite la comparaison des méthodes SA et de tests de normalité qui ont des formes renversées pour des tests similaires présentés plus tard. Aussi, autour de 50%, la pente est très franche. Malheureusement, pour la SA avec Higuchi, il y a peu de cas où le taux de détection n'a dépassé les 50%. Il n'y a donc pas de courbe pour Higuchi. Ceci souligne que différentes fonctions non-linéaires soulignent différents aspects du signal au travers de la SA.

Les travaux présentés étaient pour une seule impulsion. Par contre, on s'attend à ce que la présence d'un certain nombre d'impulsions dans une fenêtre donnée puisse avantage particulièrement la méthode de la SA. Ce travail serait intéressant à développer.

On aimerait bien conclure que la SA est sensible à la synchronisation des phases, ou plus précisément de la phase linéaire, et qu'un certain bruit peut être toléré. Par contre, d'après l'expérience numérique réalisée, on ne sait pas si c'est bien la synchronisation qui est détectée ou simplement le fait que la distribution est non-Gaussienne (la réalité étant probablement un mélange des deux). La section suivante (4.1.2) montre une situation où la seconde option est absente, i.e. la distribution est par construction parfaitement gaussienne.

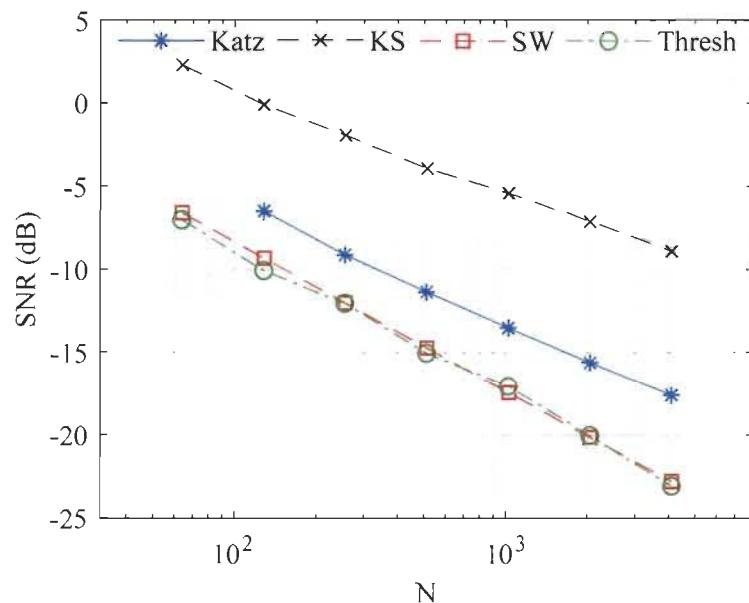


Figure 4-10 Résumé de la détection du Dirac, SNR pour taux de succès de 50%.

Il faut réaliser que pour une impulsion de Dirac dans un bruit stationnaire, le rapport signal sur bruit diminue au fur et à mesure que la fenêtre de données s'allonge. Ce phénomène a été tenu en compte dans ce qui a été présenté. Si l'on omet d'en tenir compte, la courbe pourrait avoir l'air de la Figure 4-11, à un décalage prêt (la courbe avec le seuil n'a pas été affichée).

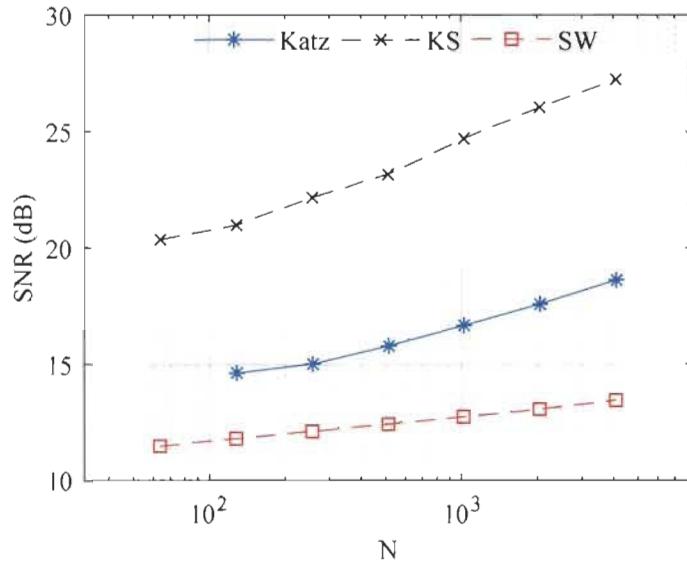


Figure 4-11 Détection du Dirac sans normalisation pour le nombre de données

4.1.2 Courbe à distribution parfaitement Gaussienne

On voudrait créer des données qui sont distribuées selon une gaussienne, mais qui seraient détectées par la SA. Première intuition erronée, utiliser justement une impulsion gaussienne, aussi appelée fenêtre gaussienne. Par contre, si la forme de l'impulsion est gaussienne, la distribution ne l'est absolument pas, comme le montre la Figure 4-12.

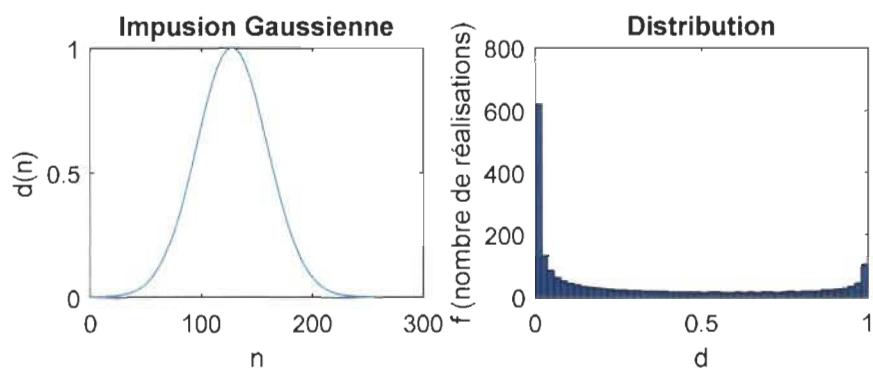


Figure 4-12 Impulsion gaussienne et sa distribution

Pour obtenir une courbe dont la distribution est gaussienne, on utilise la distribution cumulative inverse de la gaussienne, comme présentée à la Figure 4-13. Le nombre de points utilisés est 256 et ICDF signifie la fonction de distribution cumulative inverse (*ICDF – inverse cumulative distribution function*). La distribution est par construction exactement gaussienne. Le signal est fortement de type passe-bas. On observe avec intérêt que la phase est pratiquement linéaire, avec un déphasage de $\pi/2$.

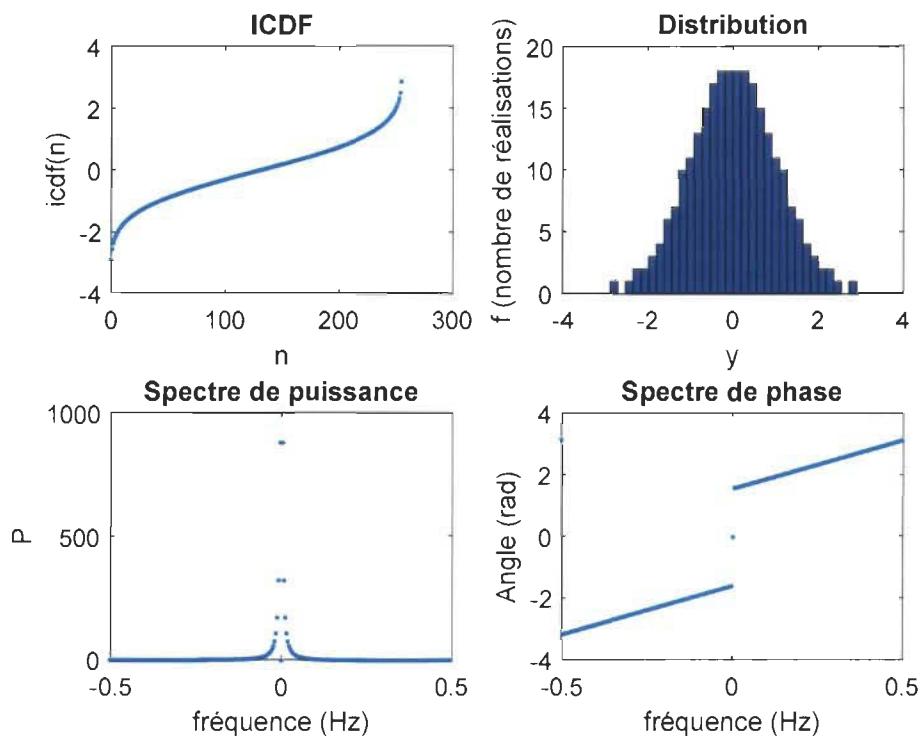


Figure 4-13 Impulsion à distribution gaussienne

Des tests ont été faits à partir de cette série et il était évident que ce signal était trop facile à détecter pour la SA. La discontinuité créée par l'extension périodique implicite à la transformée de Fourier est très évidente, comme vu à la figure Figure 4-14. Cette courbe est donc de peu d'intérêt.

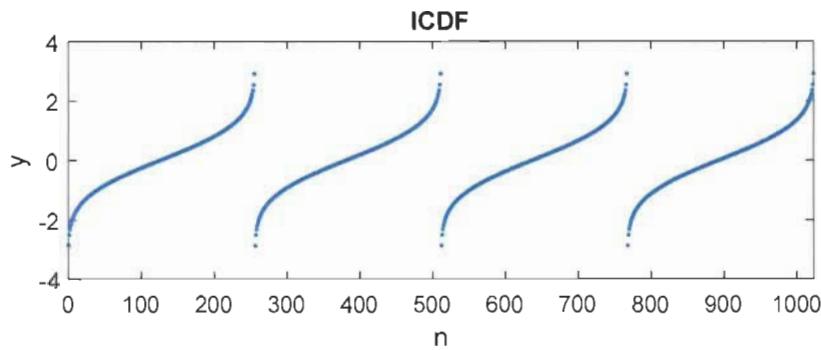


Figure 4-14 Problème de discontinuité circulaire de la courbe à distribution gaussienne

Pour créer une courbe plus pertinente, une continuité lors de l'extension périodique est ajoutée en utilisant une symétrie présentée à la Figure 4-15. Cette nouvelle courbe est composée de deux courbes parfaitement normales, mais d'ordre inverse. La résultante est encore une courbe normalement distribuée (à l'exception que toutes les valeurs sont trouvées deux fois) mais ayant une symétrie circulaire. La courbe présentée à la Figure 4-15 contient 512 points.

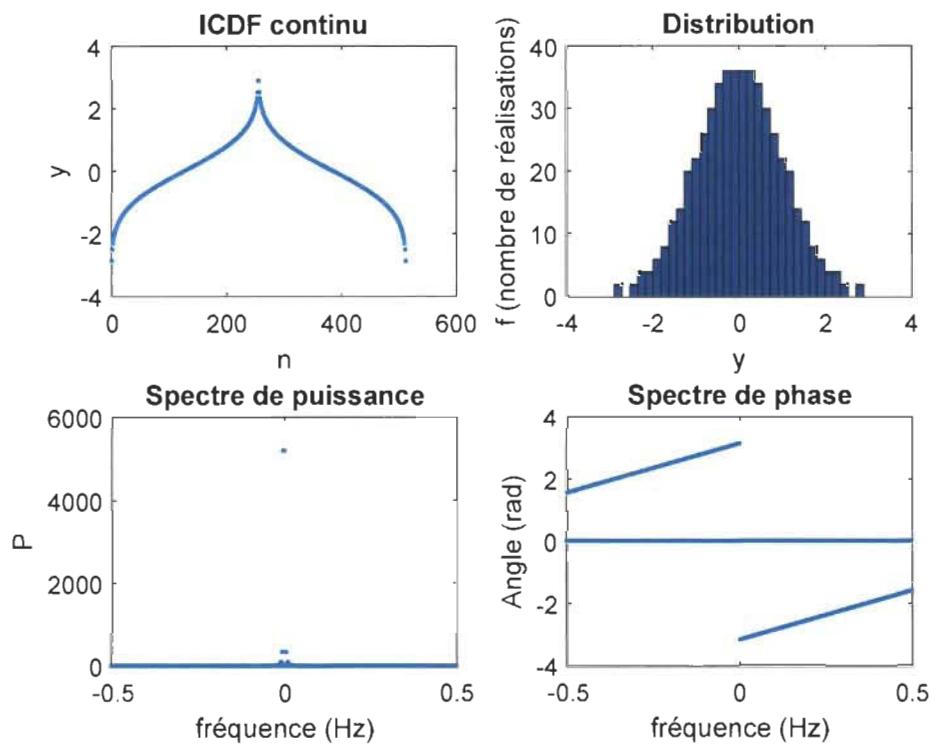


Figure 4-15 Impulsion à distribution gaussienne circulairement continue

Le spectre de phase est non seulement linéaire, mais plus précisément nul. En fait, la phase non-nulle observée est associée à des amplitudes nulles. C'est donc seulement un artéfact de la méthode de calcul du spectre de phase. En mettant les phases associées aux amplitudes nulles à zéro, on obtient le spectre de phase montré à la Figure 4-16.

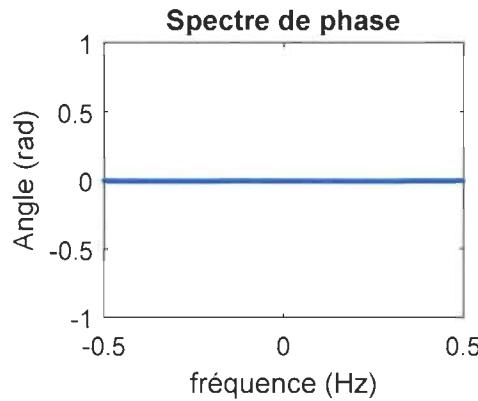


Figure 4-16 Phase corrigée de l'impulsion à distribution gaussienne

Finalement, pour obtenir une courbe plus parlante, une version décalée a été générée, commençant et finissant à zéro. Cela ne changera absolument rien aux distributions et aux résultats de la SA. Pour le spectre de phase, le décalage circulaire produit une phase linéaire, ce qui n'est pas un problème. Cette courbe est montrée à la Figure 4-17 avec le spectre fréquentiel donné en dB et le spectre de phase corrigé pour les amplitudes nulles. Cette courbe a été utilisée pour établir la détection de la phase non-aléatoire par la SA dans la publication [CAZ19].

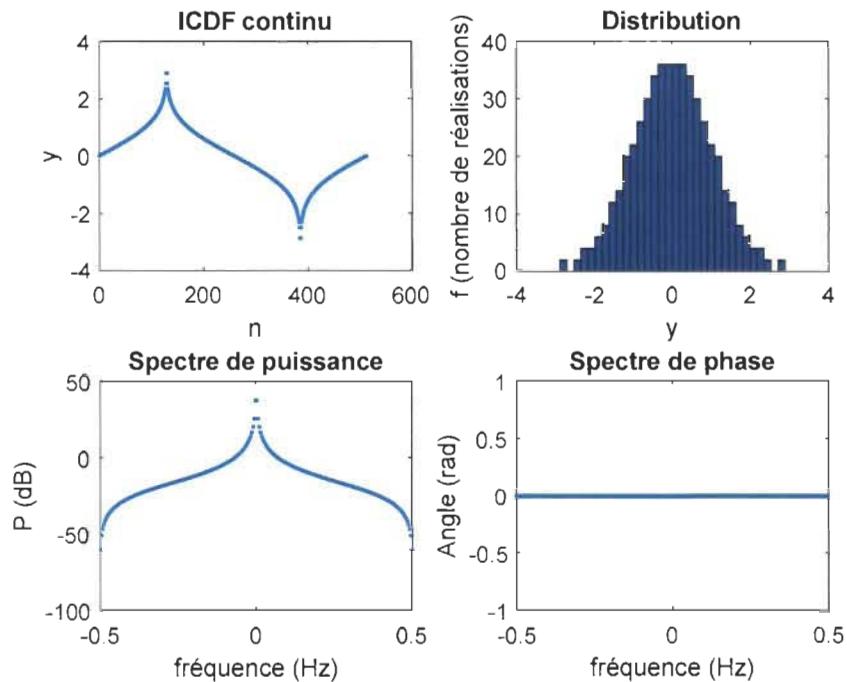


Figure 4-17 Impulsion à distribution gaussienne à début et fin nulle

4.1.2.1 Détection de la courbe à distribution Gaussienne

La détection de la courbe à distribution Gaussienne par la SA étant trop facile, un bruit est ajouté.

Ce bruit est composé de données de substitution. Le bruit a donc exactement le même spectre de puissance que le signal désiré, mais en plus, il est continu face à l'extension périodique. Aucune méthode de fenêtrage n'est donc nécessaire. Notons de plus, avec un bruit de même fréquence que le signal, le SNR ne peut être amélioré par méthodes linéaires tels un filtre de Wiener. La version bruitée de la courbe est donnée en exemple à la Figure 4-18.

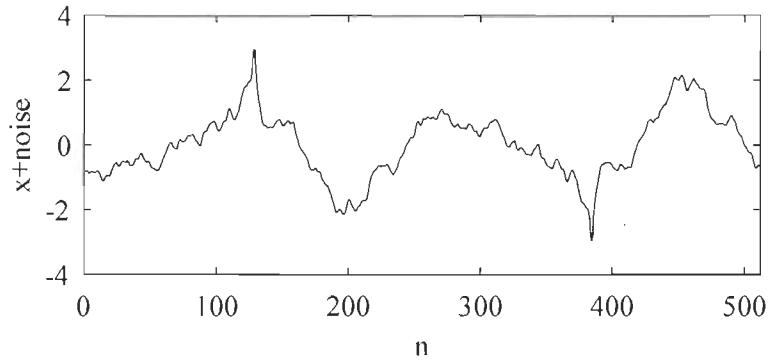


Figure 4-18 Impulsion à distribution gaussienne bruitée à (SNR = 0dB)

Les performances en termes de taux de détection selon le SNR sont montrées pour plusieurs longueurs de courbe à la Figure 4-19. Les méthodes SA sont comparées aux tests de normalité.

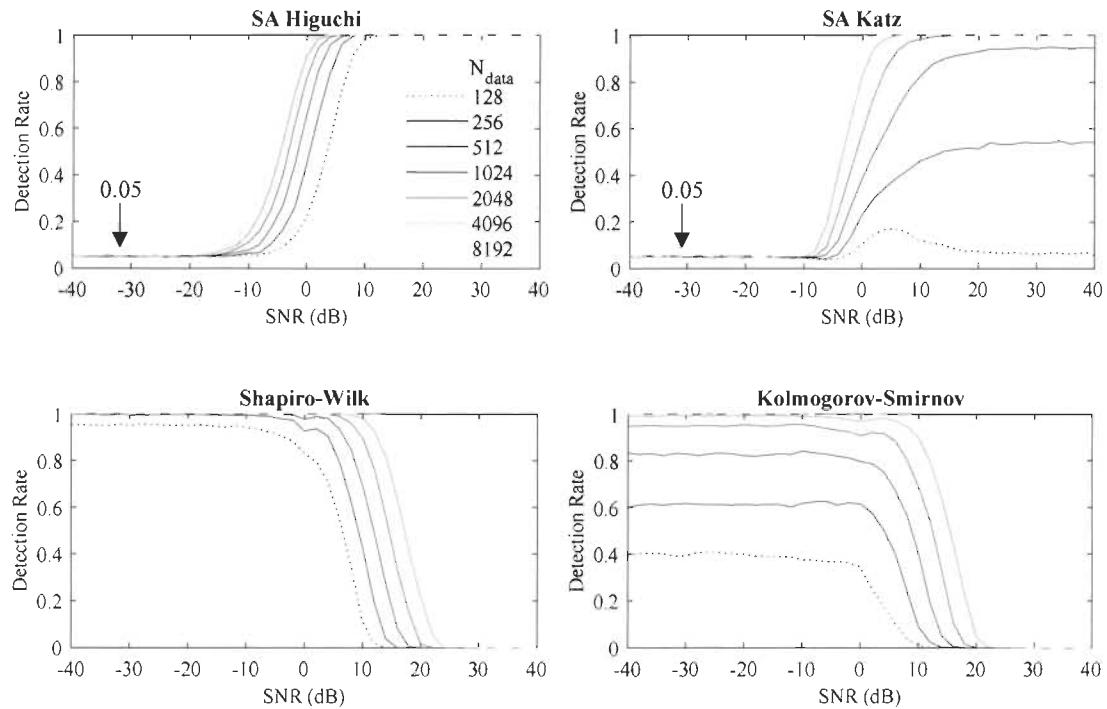


Figure 4-19 Détection de l’impulsion à distribution gaussienne bruitée

Pour la SA, les résultats sont prévisibles : plus les fenêtres de données sont longues, plus les courbes sont détectées aisément. Aussi, le taux de faux positifs, qui équivalent au taux de détections vers lequel tend asymptotiquement les performances lorsque le SNR diminue, est de 5%, encore une fois ce qui est attendu. Les tests de normalité ont par contre apporté un élément

inattendu : l'hypothèse nulle est rejetée lorsque le SNR est bas. Donc, on conclut que le bruit formé de données de substitution n'est pas nécessairement distribué selon une loi normale. En générant 10000 séries de substitution d'une longueur de 512 et en normalisant, on obtient une distribution du signal présentée à la Figure 4-20.

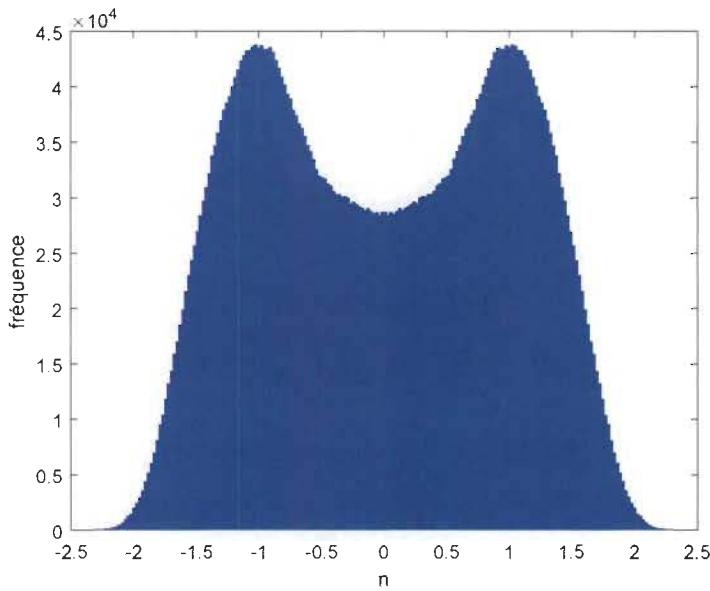


Figure 4-20 Distribution du bruit fait par données de substitution

Il serait intéressant de comparer théoriquement la distribution des données de substitution et de données stochastiques de même spectre mesurées sur une même taille de fenêtre. Il est connu que la distribution du processus ARMA suit une loi normale. Cependant, la distribution d'une fenêtre de données d'un processus stochastique semble être encore un problème ouvert.

On interprète donc les résultats des tests de normalité dans le sens inverse. En absence du signal désiré, il est attendu que la distribution ne soit pas normale. Mais quand le signal désiré est fortement présent, la distribution devient normale. Aussi, plus le signal est long, moins la normalité est détectée rapidement, encore une fois contraire à ce qui est attendu.

Pour comparer les performances de la SA et des tests de normalité, le SNR nécessaire pour obtenir un taux de détection de 50% est utilisé, puisqu'il permet de comparer un nombre raisonnable de points. Les résultats sont présentés à la Figure 4-21.

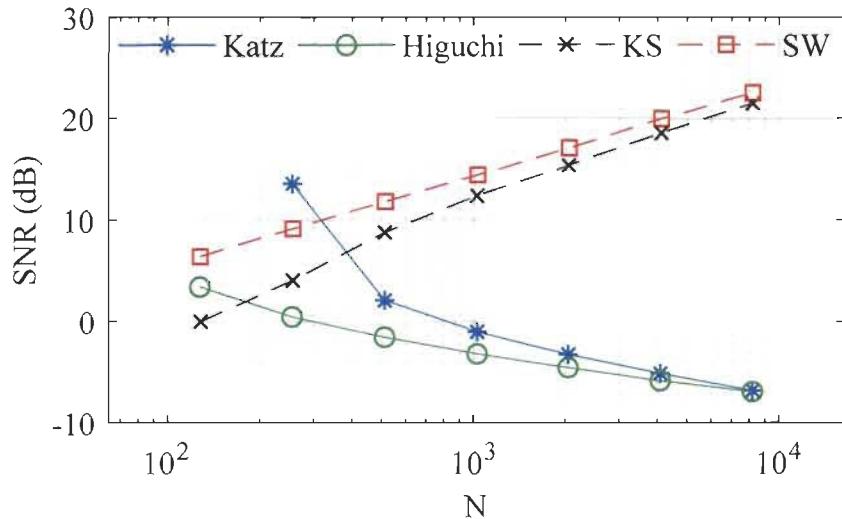


Figure 4-21 Résumé de la détection de l'impulsion à distribution gaussienne, SNR pour taux de succès de 50%

4.1.2.2 Détection de la courbe à distribution Gaussienne, version BPSK

Une extension de la détection de la courbe développée se trouve lorsque celle-ci est répétée à plusieurs reprises. À part la réplique des valeurs, la distribution est Gaussienne. Or, simplement répéter la même courbe est un cas particulier d'un type de signal plus large. En utilisant la courbe à distribution Gaussienne comme impulsion pour moduler un signal binaire symétrique (BPSK), on peut obtenir encore une fois des courbes à distribution Gaussiennes, mais plus intéressante et possiblement près d'applications pour les télécommunications. La Figure 4-22 présente un exemple de signal à 8 bits et 128 données par impulsion.

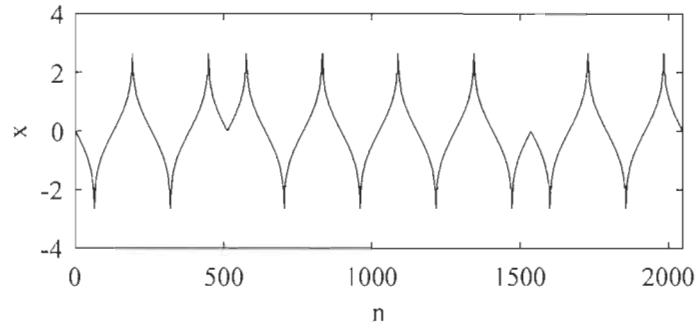


Figure 4-22 Impulsion à distribution gaussienne pour un signal BPSK de 8 bits

Encore en utilisant un bruit à base de données de substitution, les performances des méthodes de SA et de tests de normalité face à la détection d'un signal dans ces conditions sont montrées à la Figure 4-23.

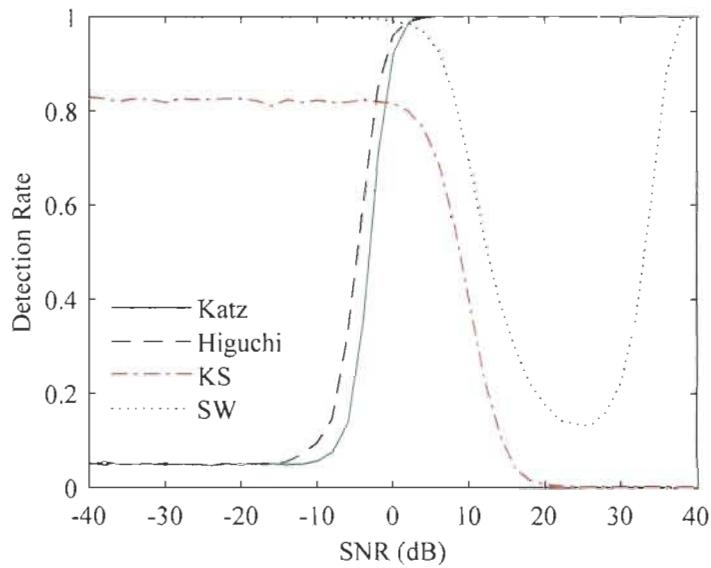


Figure 4-23 Détection de l'impulsion à distribution gaussienne pour un signal BPSK de 8 bits

Ici, les performances sont intéressantes pour les deux méthodes de SA. Pour le test de Shapiro-Wilk, à très haut SNR, la méthode détecte la répétition des données. Une étude complète de l'impact du nombre de données par courbe et par message binaire serait intéressante.

4.1.2.3 Détection de l'ECG dans du bruit

La détection de l'ECG dans un bruit a été publiée [CAZ19]. Pour le signal désiré, des segments d'ECG obtenus sur la banque de données Physionet [BOU95] sont utilisés, un exemple étant montré à la Figure 4-24. Bien qu'un bruit soit nécessairement inclus dans les données expérimentales, les segments sont considérés sans bruit.

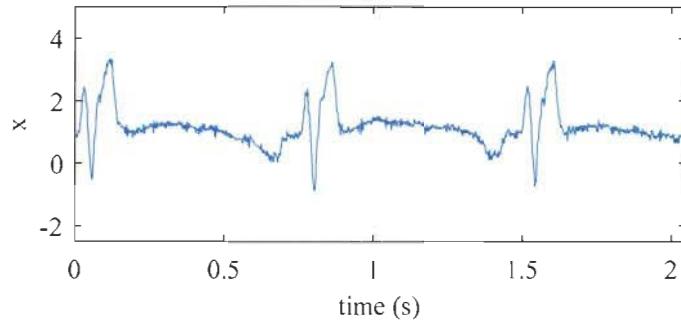


Figure 4-24 Exemple de signal ECG

Aux segments d'ECG, du bruit blanc est ajouté. Le signal bruité pour un SNR de 0 dB est montré à la Figure 4-25.

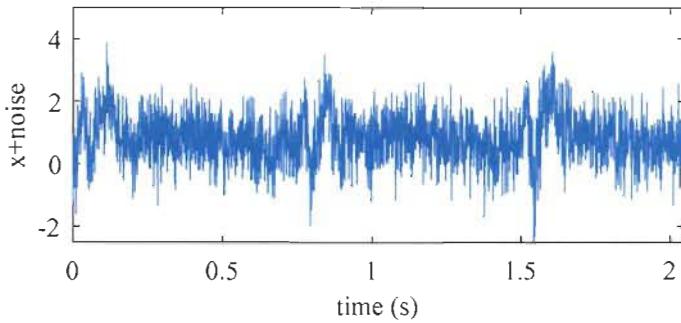


Figure 4-25 ECG bruité à 0 dB

Ce signal est ensuite filtré par un filtre passe bande avec fréquences de coupures de 1Hz et 40Hz (Figure 4-26). Le bruit résiduel est donc corrélé, un peu similairement à la situation précédente où un bruit composé de données de substitution était utilisé. Un fenêtrage est utilisé pour réduire les effets de bord. Le signal fenêtré est montré à la Figure 4-27.

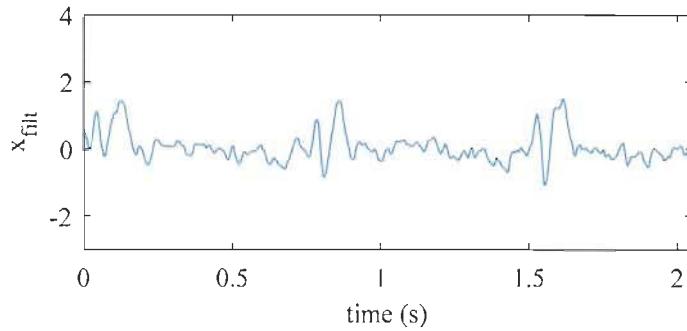


Figure 4-26 ECG après filtrage

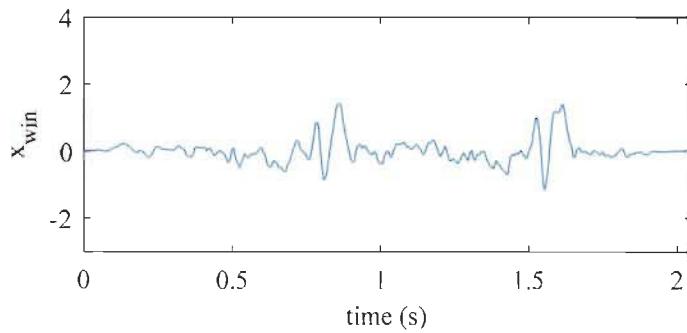


Figure 4-27 ECG après fenêtrage

La même fenêtre est appliquée aux données de substitution. La distribution des dimensions Fractales des données de substitution et de la série originale est montrée à la Figure 4-28. La tige est associée à la série originale et seule sa position en abscisse est significative, sa valeur en ordonnée étant simplement choisie pour faciliter la comparaison.

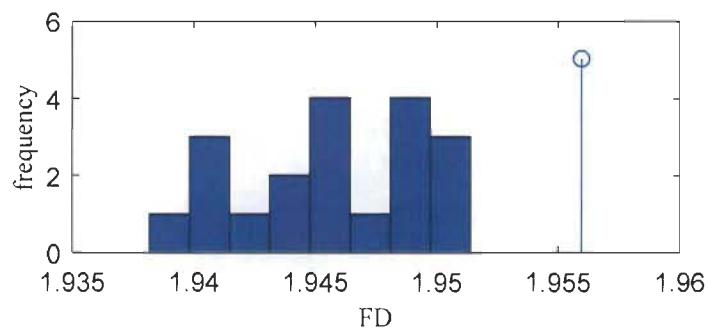


Figure 4-28 Exemple de SA pour détection de l'ECG

Quoique la détection ne nécessite que les 19 séries, un histogramme utilisant 5000 séries de substitution. Dans l'exemple présenté, la valeur p obtenue devient $p = 0.0195$ tandis que pour les 19 séries, on ne sait seulement que $p < 0.05$.

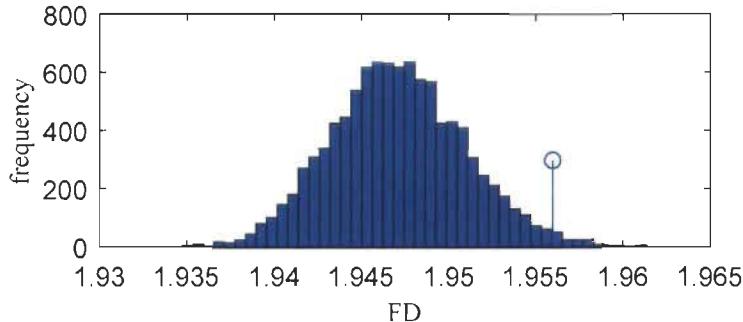


Figure 4-29 Exemple de SA pour détection de l'ECG, 5000 séries de substitution.

Les performances de détection du ECG selon le bruit sont présentées à la Figure 4-30. Les méthodes utilisant la SA sont comparées aux méthodes de statistiques d'ordre supérieures et aux tests de normalité. Les différentes approches sont calibrées pour donner 5% de faux positifs à bas SNR. Bien qu'un seul capteur d'un seul sujet soit étudié, plus de 1000 fenêtres avec 30 générations de bruits sont utilisés pour établir ces courbes.

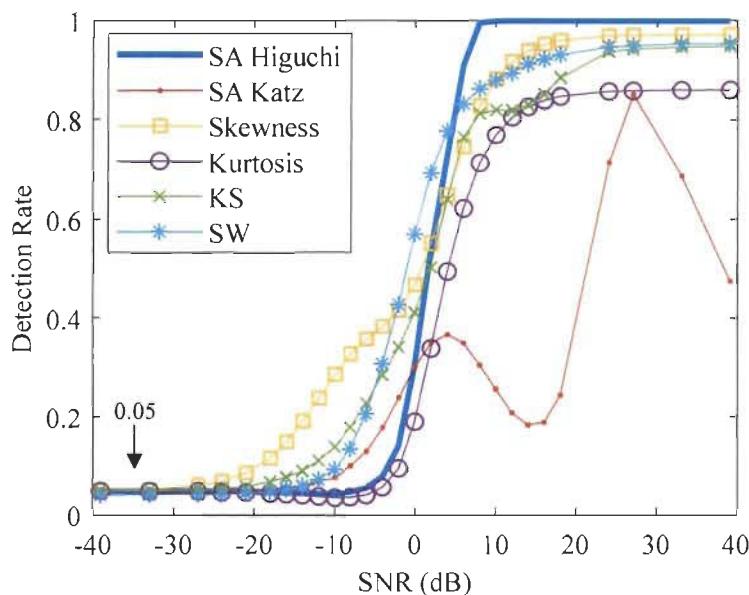


Figure 4-31 Performance de détection de l'ECG

Il est clair qu'aucune méthode ne domine les autres pour tout SNR. Par contre, la SA avec Higuchi est la seule à atteindre 100% de succès à SNR élevé.

4.1.2.4 Estimation du rythme cardiaque dans un bruit

En utilisant une fenêtre mobile, le score de la SA varie au rythme du battement cardiaque. On montre que le rythme cardiaque peut être estimé selon la variation de la SA. La SA est résistante à un certain bruit de même spectre de fréquence que le signal désiré. En comparant la SA à d'autres méthodes, elle se présente avantageuse lorsque le niveau de bruit est élevé.

La série de données d'ECG est présentée à la Figure 4-32. Bien qu'elle contienne certainement un niveau de bruit, elle sera considérée idéale. Un bruit sera rajouté à ce signal.

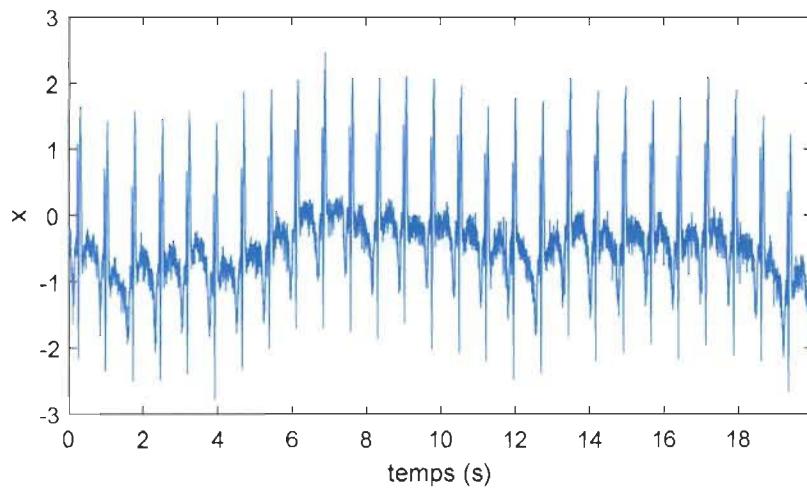


Figure 4-32 Séquence ECG non bruité

Le signal avec un bruit produisant un SNR de 10 dB est montré à la Figure 4-33. On voit encore clairement les pics.

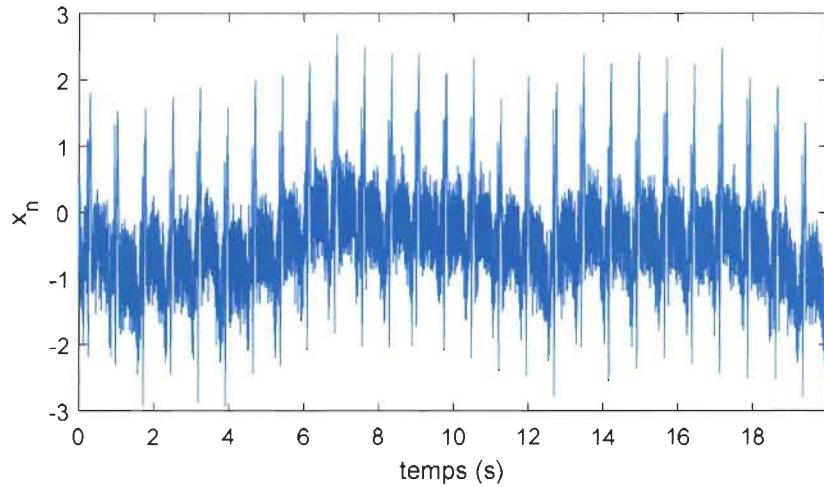


Figure 4-33 Séquence ECG, 10 dB

Un filtre passe-bande est utilisé avec fréquences de coupure de 1 et 40 Hz. Le signal obtenu semble plus net que le signal original, considéré sans bruit.

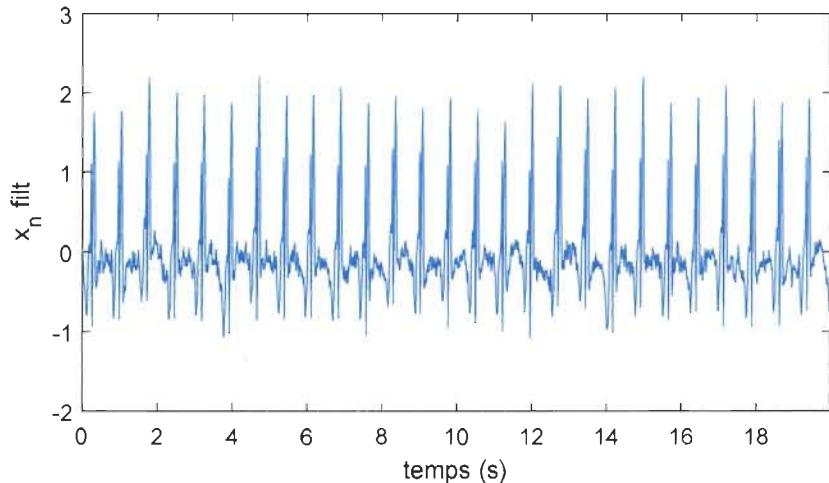


Figure 4-34 Séquence ECG après filtrage

Une fenêtre coulissante d'environ 2 secondes (2048 échantillons) de données est utilisée avec méthode de fenêtrage du Tukey (paramètre ajusté à 0.5) avec un intervalle de 32 échantillons entre chaque fenêtre. Le sous-échantillonnage des fenêtres a été fait pour réduire le temps de

calcul. Pour chaque fenêtre la SA, la variance, la MDF, la FD selon Higuchi et un rapport de la FD sur la MDF sont calculés. Les résultats pour la SA sont montrés à la Figure 4-35.

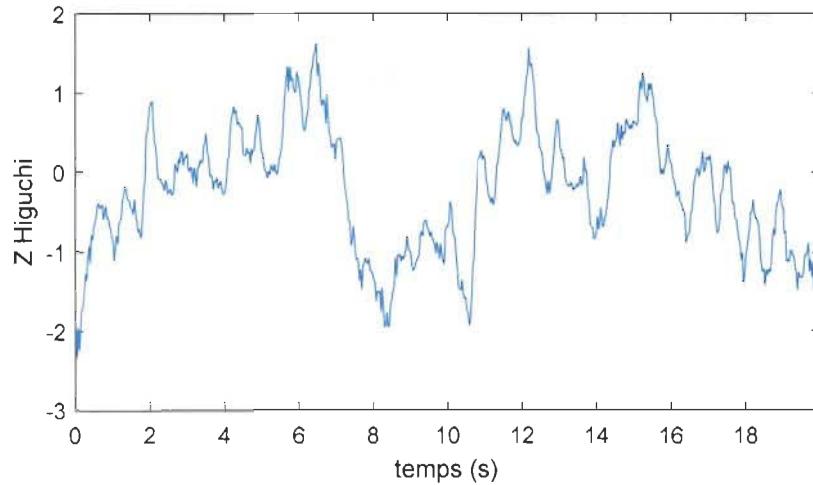


Figure 4-35 Score de la SA selon le temps pour l'ECG

Étant donné que le rythme cardiaque varie généralement dans une certaine plage, un filtre passe-bande aux fréquences de coupures associées à la plage 40-200 battements par minutes est utilisé pour éliminer les oscillations superflues. Le résultat est montré à la Figure 4-36.

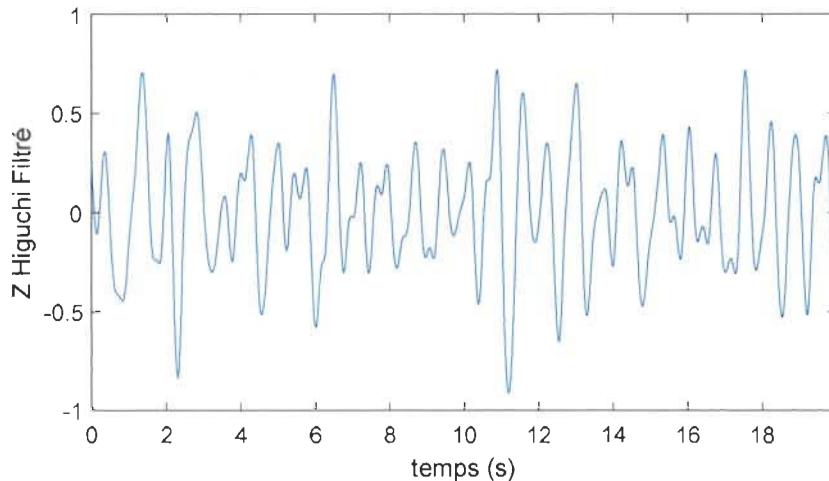


Figure 4-36 Score de la SA selon le temps, filtré

Une simple détection de signe montre déjà une certaine reconnaissance des pics à la Figure 4-37.

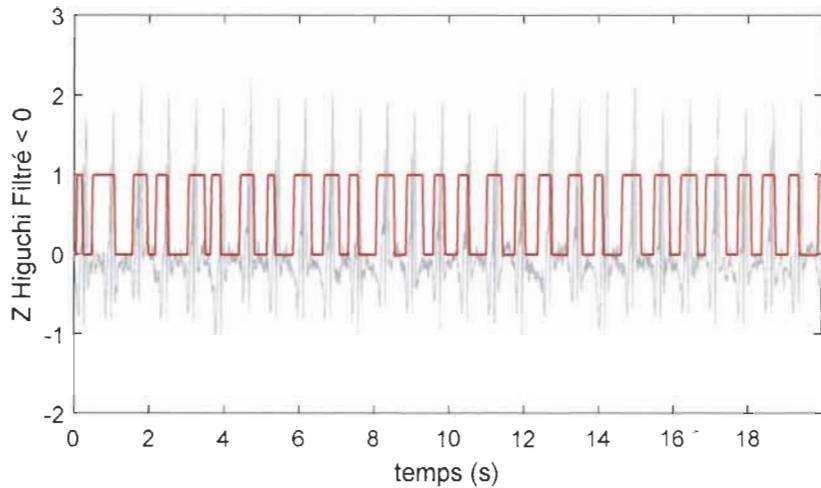


Figure 4-37 Détection du signe du score de la SA, SNR à 10dB

En utilisant le front montant et éliminant les fronts consécutifs trop rapprochés, on obtient une détection des pics présentés à la Figure 4-38 qui seront comptés pour établir le rythme cardiaque. Notons un léger retard de la détection des pics sur le battement cardiaque qui est un effet de fenêtrage.

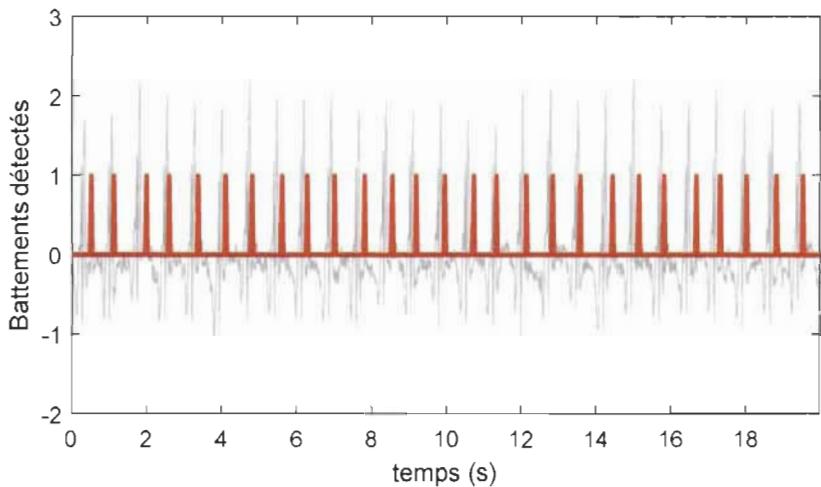


Figure 4-38 Résultat de la détection de battement cardiaque par la SA, SNR à 10dB

Un exemple à 0 dB est montré à la Figure 4-39, avec les résultats donnés à la Figure 4-40.

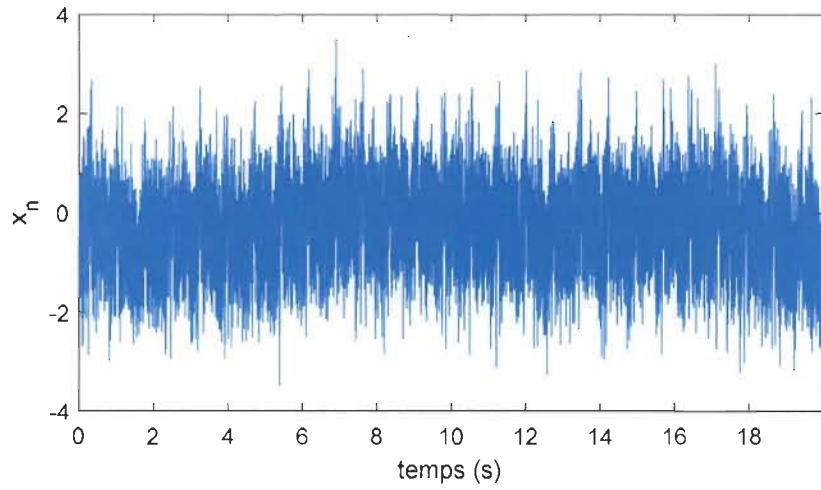


Figure 4-39 Séquence ECG bruitée à 0dB

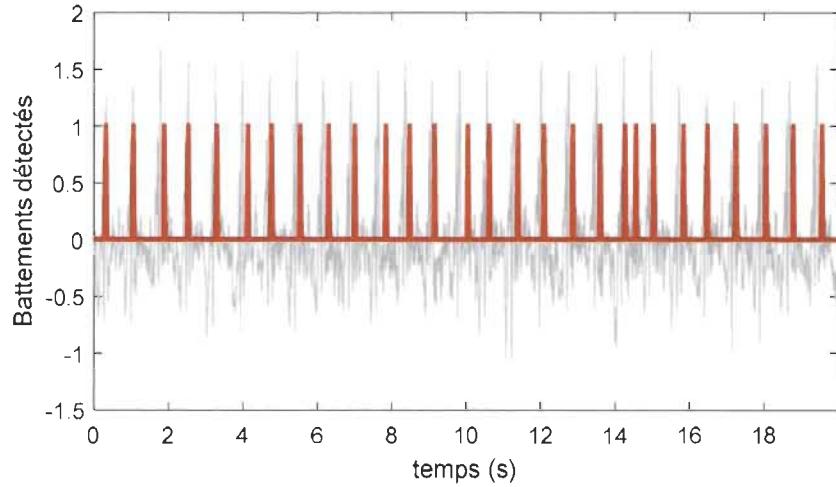


Figure 4-40 Résultat de la détection de battement cardiaque par la SA, 0dB

La détection des pics est encore presque parfaite, mais on voit un pic supplémentaire, vers les 15 secondes. Aussi, il y a plus de variabilité dans la position des pics.

Les performances d'estimation du rythme cardiaque sont montrées à la Figure 4-41. On remarque que pour les niveaux de SNR extrêmement bas, certains algorithmes semblent meilleurs que les autres. Ceci est toutefois complètement absurde. À -100 dB, ce n'est à toutes fins pratiques que du bruit. Différents algorithmes donnent différents rythmes cardiaques pour

un signal purement aléatoire. Ce qui doit être observé, c'est le SNR pour lequel l'algorithme « décroche », ou la position du coude de la courbe.

Le SNR exact a été sélectionné à partir de la méthode de seuil, sans bruit. Évidemment la méthode de seuil fonctionne parfaitement si elle est comparée à elle-même. Les autres méthodes ont toutes une erreur par rapport au seuil. Cependant, les autres méthodes utilisent des fenêtres et filtrage qui créent un certain décalage difficile à calculer. Les données ont été calculées sur une vingtaine de secondes. Un pic de plus ou moins et il se produit une différence de 3 battements par minutes. La Figure 4-42 montre une version modifiée où chaque algorithme est comparé à un rythme cardiaque donnant les meilleures performances, sans nécessairement être exact.

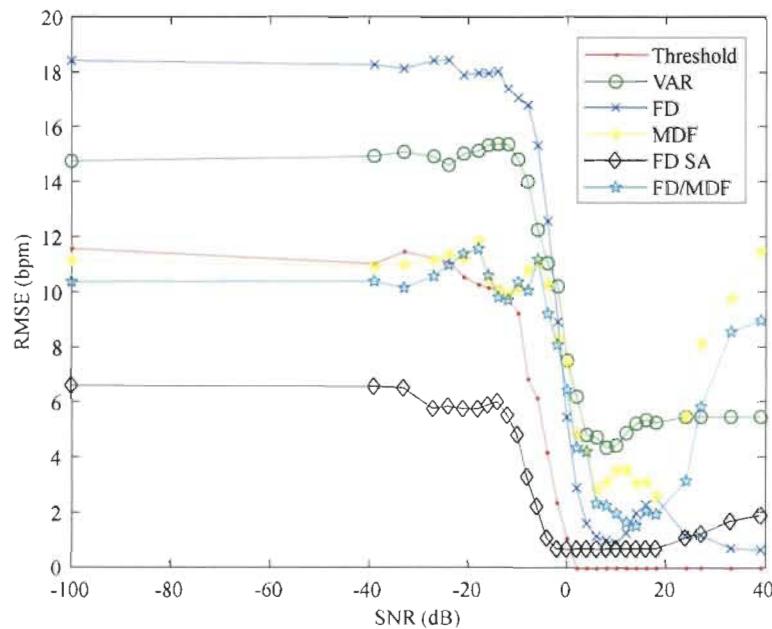


Figure 4-41 Performances d'estimation du rythme cardiaque, référencées sur le seuil sans bruit

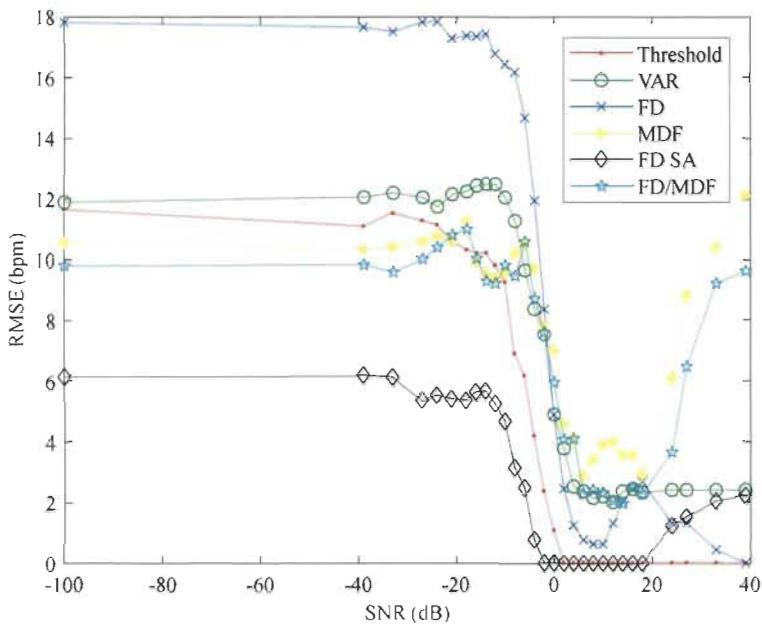


Figure 4-42 Performances d'estimation du rythme cardiaque, référencées sur les meilleurs résultats de chaque méthode

De ce graphique, on constate qu'à part le seuil, la SA est la méthode la plus fiable pour un large domaine de SNR. Notons que pour plusieurs courbes, les résultats ne passent même pas par une erreur nulle alors que le rythme cardiaque de comparaison est sensé minimiser l'erreur. L'erreur résiduelle est donc causée par l'effet du bruit variant d'un test à l'autre. La SA est robuste au bruit. En fait, elle semble même avoir besoin d'un certain niveau de bruit. En effet, au-delà de 20 dB, les résultats se détériorent. Cela est dû au fait que la SA détecte des éléments du ECG qui sont difficiles à percevoir. Cependant, pour un système pratique, il existe déjà des méthodes efficaces pour de tels niveaux de bruit. La SA est la seule à ne pas décrocher avant un SNR de -2 dB. Il resterait évidemment beaucoup de travail pour faire de la SA un estimateur de rythme cardiaque assez solide pour mériter d'être employée malgré sa complexité largement accrue face au simple seuil. Toutefois, c'est une option viable dans le cas où une large résistance au bruit est souhaitable.

4.2 SYNCHRONISATION DES POTENTIELS D'ACTION ET VITESSE DE CONDUCTION

Ce que cette section amène est une nouvelle interprétation de la SA associé au contexte de l'EMG. L'idée est que le résultat de la SA est lié à la synchronisation d'impulsions. Dans le cas précis de l'EMG, on parle de synchronisation des potentiels d'action des unités motrices. La méthode proposée est validée et fait l'objet d'un article soumis à un journal [CAZ20c].

L'intérêt de l'étude sur la synchronisation des potentiels d'action d'unités motrices remonte à loin [FUL25][ADR33] et est toujours d'actualité [FAR15]. Ce phénomène de synchronisation est complexe, provenant à la fois de cause physiologiques que de stratégies de contrôle [FAR15]. L'analyse visuelle est certainement insuffisante pour l'observée. La présence de synchronisation neuronale a été déterminée par des méthodes d'histogrammes [TAY62][MOO66] [MIL73][SEA76]. Une détection de pics est effectuée sur deux canaux. Un histogramme de la position des pics du second canal par rapport aux pics du premier est obtenu. Cette approche est toujours utilisée [FAR15]. Une bonne revue historique de l'établissement de la synchronisation se trouve dans [DAT90]. Cependant, la compréhension du phénomène est toujours un sujet d'étude actuel [FAR15]. La synchronisation est d'un intérêt important dans l'étude la maladie de Parkinson [HAM07]. Elle a aussi été étudiée par rapport au vieillissement [KAM00] et la fatigue [BOO08].

Le sujet de la synchronisation est aussi d'intérêt pour la neurologie. Par contre, la littérature est présentement axée sur la synchronisation de régions différentes, pouvant être interprétée comme un élément de communication entre différentes parties du cerveau [BEN04]. Particulièrement, l'intérêt est généralement d'étudier la synchronisation entre différents groupes de neurones [WOM07]. Aussi, la synchronisation a des impacts différents selon la bande de fréquence considérée [FRI01]. Notons que la notion de synchronisation est plus récemment appelée

cohérence [FRI15][BAS15]. Un aspect de synchronisation ou cohérence locale ne semble pas d'intérêt direct dans la littérature. Il est par contre concevable que la caractéristique permette d'aborder cet aspect. De plus, on peut imaginer une étude de la synchronisation entre deux régions en tenant compte des synchronisations locales.

4.2.1 Relation SA et synchronisation

Idéalement, on aimerait une belle relation monotonique entre la SA et la synchronisation. Bien que les résultats présentés ici démontrent un tel comportement, ceci est dans le contexte où les signaux sont parfaitement synchronisés. Dans une situation réelle, on s'attend à des décalages entre les impulsions. Selon la forme de l'impulsion, ou sa bande passante, la relation entre la SA et la synchronisation sera plus ou moins affectée par un décalage. Certaines situations pourraient rendre la relation non monotonique.

Une étude complète établissant les relations entre le résultat de la SA et les différents facteurs reste à faire. On voudrait obtenir une équation de la forme :

$$SA = f(S, CV, d, \Delta t) \quad (4-1)$$

où S est le taux de synchronisation, CV est la vitesse de conduction, d est la distance du capteur par rapport à l'impulsion, Δt est le décalage temporel. Rajoutons que la longueur des séries de données peut aussi affecter les résultats. Cette relation devrait être aussi établie pour différentes formes d'impulsion typiques, des superpositions de formes non-identiques, des vitesses de conductions variables et pour des trains d'impulsion, et ce pour différentes caractéristiques non-linéaires. Malgré cela, cette analyse reste simpliste face au problème réel. Le champ électrique extracellulaire du potentiel d'action des unités motrices est extrêmement complexe.

Si l'objectif est d'obtenir de la SA le taux de synchronisation (ou autre paramètre), il est peu probable de pouvoir inverser la fonction avec une seule caractéristique. Il est envisageable de produire cette inversion par l'utilisation de plusieurs caractéristiques et un algorithme de classification non-linéaire. Même si cette inversion est montrée possible pour un modèle simple, il est loin d'être démontré qu'on peut identifier le taux de synchronisation de manière précise par l'utilisation de la SA dans un contexte réel.

Néanmoins, dans le contexte de classification, il n'est pas si important d'identifier les différentes variables affectant la SA. Aussi, parmi les différents facteurs affectant la SA, le taux de synchronisation est possiblement celui qui est le plus sujet à une variation, le reste des facteurs étant principalement liés à la position des capteurs ou variant lentement (comme la vitesse de conduction). L'utilisation de la SA permet donc d'extraire une information liée à la synchronisation qui peut être utilisée pour la classification.

Dans le cadre des travaux de la thèse, il n'y a pas d'affirmation comme quoi l'information acquise sur la synchronisation améliore la classification. Ceci n'est en aucun cas démontré. Ce qui est affirmé est cette possibilité. Mathématiquement, il peut y avoir un lien. Aussi, il est possible que l'effet de la synchronisation vienne plutôt agir comme un bruit, nuisant à la classification. Ce serait le cas si la variabilité de la synchronisation est importante entre différents sujets mais pas entre les groupes.

4.2.2 Définitions de la synchronisation dans la littérature

Dans la littérature, on retrouve diverses définitions liées à la synchronisation des potentiels d'action. Une première approche s'intéresse aux temps entre les impulsions de deux endroits différents [SEA76]. Une méthode d'estimation basée sur l'histogramme de temps entre les pics

de potentiels d'action de deux régions différentes est utilisée et illustre bien le critère. Elle est développée dans le cadre d'expériences où l'accès aux motoneurones est disponible par l'utilisation d'EMG intramusculaire, par exemple dans [KAM00]. Une version adaptée pour la sEMG est étudiée dans [YUE95] mais est montrée peu fiable.

Une autre définition du taux de synchronisation est donnée pour le cas des trains d'impulsion [HER92]. Cette définition s'intéresse non pas à la synchronisation entre différentes unités motrices mais plutôt à la régularité du train d'impulsion.

Aussi, peut-être un des modèles les plus à jour pour expliquer la synchronisation des unités motrices [FAR15] amène une distinction entre la synchronisation causée par l'anatomie et par les stratégies de recrutement des unités motrices. L'accent est mis dans ce cas sur le recrutement pour calculer un taux de synchronisation.

Finalement, la définition de la synchronisation peut-être la plus proche de celle utilisée est décrite dans [YAO00]. Elle est basée sur un modèle où plusieurs fibres ont des trains d'impulsions identiques. Les impulsions sont placées à intervalle régulier mais avec une erreur aléatoire ayant une déviation standard de 20%, similaire à [SEA76]. La synchronisation est créée en enlignant une certaine proportion des pics. Elle est similaire à l'approche présentée en ce que la mesure se fait en un point, les impulsions sont toutes identiques et la distance de mesure est supposée constante par rapport à toutes les fibres. Cependant, dans les simulations présentées ici, seule une impulsion dominante est considérée. La définition de [YAO00] a été utilisée pour l'étude de l'impact de la synchronisation sur une caractéristique non-linéaire, le pourcentage de déterminisme (%DET) dans [FAR02]. Ce qui est montré ici est une extension du principe appliqué à la SA.

4.2.3 Model employé

Le model employé dans ce qui est présenté ici a été notamment dans [BOY78] et [HER92]. Bien que désuet, extrêmement simpliste et irréaliste, le concept est clairement montré et il est évident que des simulations sur modèles plus évolués pourraient aisément être réalisés. On étudie le passage de plusieurs dipôles dans des fibres musculaires.

Les seules variables considérées sont :

- la distance entre les charges,
- la distance du capteur,
- la vitesse de conduction,
- le nombre de fibres (ou d'impulsions),
- le taux de synchronisation,
- la méthode de fenêtrage

Le modèle est encore plus simplifié que celui de [BOY78] en ce sens que toutes les fibres sont considérées à une même distance du capteur. On ne simule pas de modèle tridimensionnel. Ceci permet de souligner le fait que la SA est sensible à la synchronisation même sans distribution spatiale.

4.2.4 Modèles plus réalistes

Parmi les modèles plus élaborés de potentiels d'action (d'unité motrice ou neuronal) mais aisément calculables et adapté pour reproduire le type de tests présentés, le modèle de Hodgkin-Huxley [HOD52] du potentiel d'action neuronal est certes le premier qui vient à l'esprit. Cependant, ce modèle est intracellulaire. Un modèle extracellulaire du potentiel d'action neuronal relativement simple est trouvé dans [CLA68]. Une version musculaire de ce modèle

est dérivée dans [PLO74]. Le même modèle est étudié dans [MCG88] en tenant compte des effets de bords des jonctions neuromusculaires. Ces modèles extracellulaires sont tripolaires. Notons que les modèles d'unités motrices simulent un volume de conduction dans laquelle plusieurs fibres sont contenues, souvent simplement un cylindre ayant des fibres distribuées aléatoirement. Des modèles plus ressent existent, mais c'est surtout cette distribution spatiale qui est travaillée. Un bon exemple est [FAR04]. Finalement, des méthodes pour simuler des trains d'impulsion assez simples sont disponibles. Notamment, on peut considérer un train avec une variabilité de la position étant une simple gaussienne [HER92]. L'effet du bruit sur une méthode d'estimation de la synchronisation est décrit dans [YUE95]. Évidemment, une évaluation de la sensibilité face au bruit est nécessaire. Finalement, une bonne revue de la littérature des modèles de sEMG se trouve dans [STE00]. Chaque modèle devrait être utilisé pour analyser les performances de la SA pour obtenir le taux de synchronisation.

4.2.5 Simulations faites en exemple

Seules quelques simulations ont été faites jusqu'à présent pour illustrer l'idée. Chaque paramètre du modèle a son impact. Seule une étude limitée est montrée ici. Seul le taux de synchronisation et la vitesse de conduction sont variés, le reste des paramètres étant gardé constant.

La Figure 4-43 présente le signal de base, un exemple de signal non synchronisé et deux signaux ayant des faibles taux de synchronisation. Les paramètres pour la génération du signal de base ont été choisis pour montrer une situation réaliste malgré la simplicité [BOY78]. Le signal de base est obtenu à partir d'un modèle de dipôle circulant dans une fibre infinie. La distance de mesure est de 1 cm et la distance entre les charges est de 1 mm. Les signaux non-synchronisés sont bâtis à partir de 500 impulsions. Le taux d'échantillonnage est de 1 kHz. La vitesse de conduction a varié dans les simulations. Dans les graphiques de la Figure 4-43, elle est de 4.1

m/s, telle que suggéré par [BOY78]. Le même signal non-synchronisé est utilisé pour plusieurs taux de synchronisation. Notons que dans [BOY78] les signaux proviennent de fibres placées à différentes distances. Dans le modèle utilisé, les fibres sont simulées comme provenant du même emplacement.

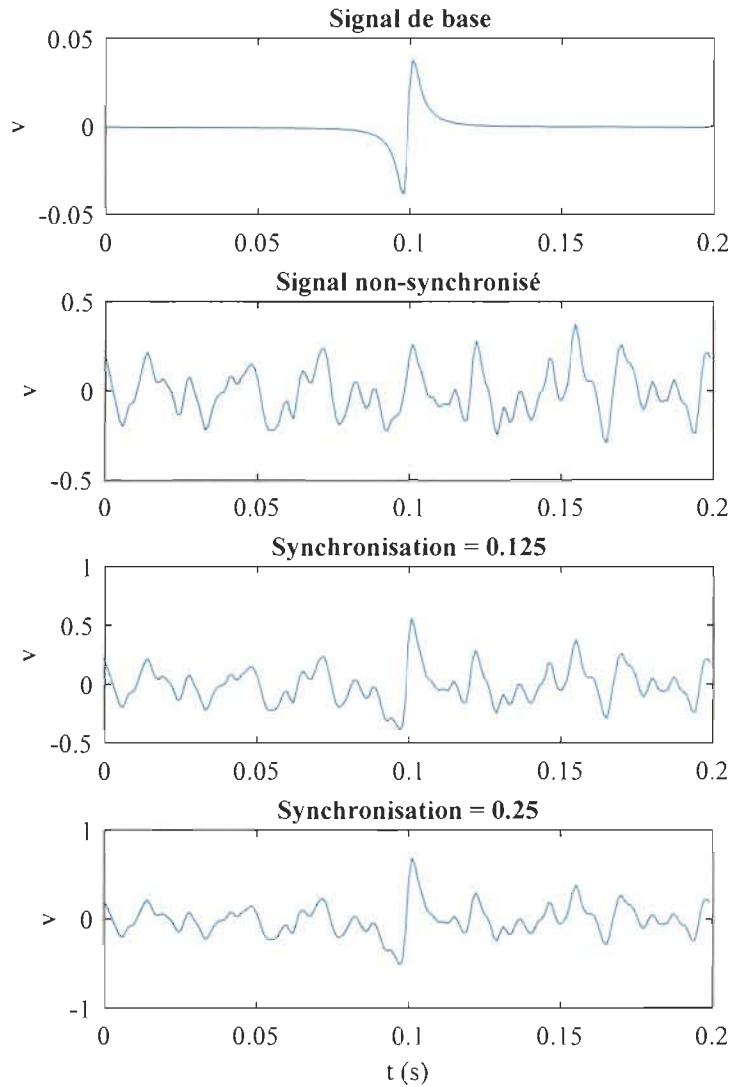


Figure 4-43 Signal de base, exemple de signal non synchronisé et signaux avec taux de synchronisation faibles.

4.2.6 Résultats de simulation

Les principaux résultats de simulation obtenus sont présentés ici. On s'intéresse premièrement aux résultats moyens, présentant les tendances des caractéristiques obtenues en fonction du taux

de synchronisation et de la vitesse de conduction. Cette section s'intéressera brièvement à la variabilité des caractéristiques. Deux objectifs sont à garder à l'esprit en analysant les résultats :

- 1- interpréter la SA dans le cadre de son utilisation comme variable discriminante ou caractéristique du signal tel que présenté dans la thèse, et
- 2- montrer la possibilité d'évaluer les paramètres du système

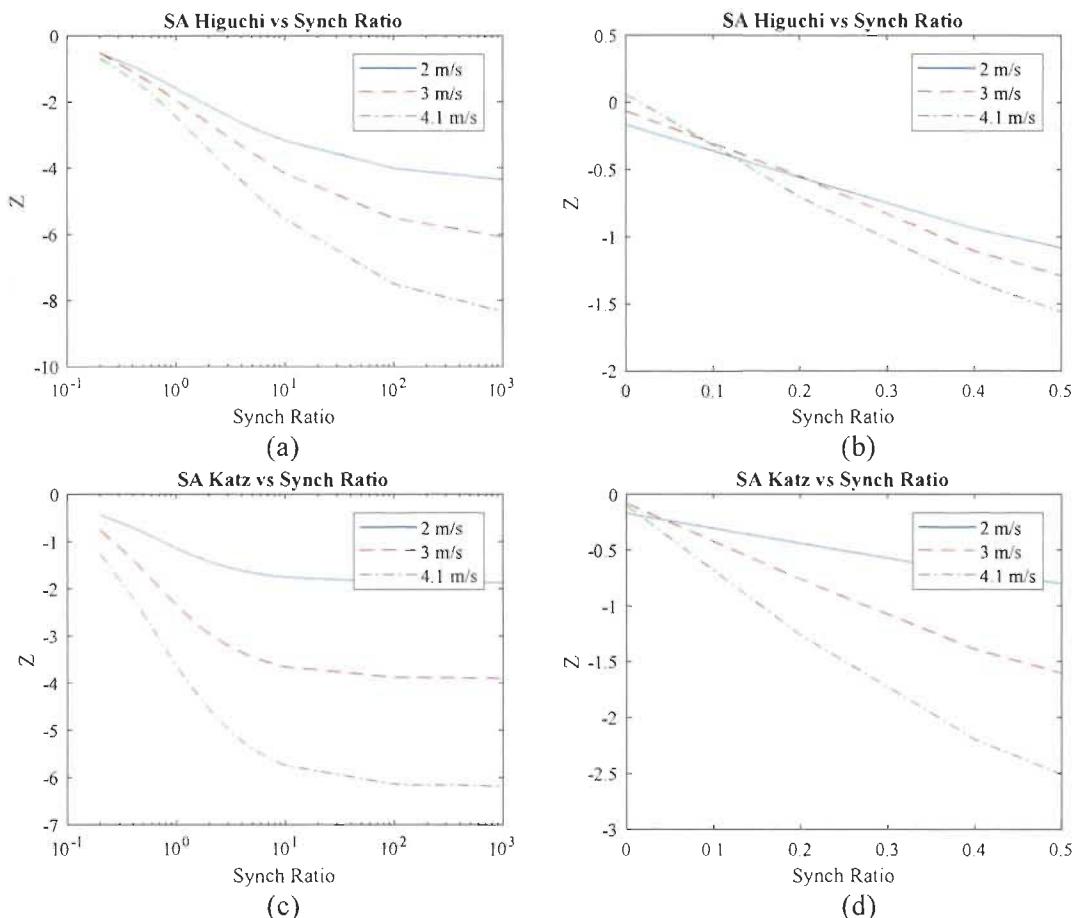


Figure 4-44 Résultat moyens de la SA selon le taux de synchronisation pour différentes vitesses de conductions

La Figure 4-44 montre l'impact de la synchronisation et de la vitesse de conduction sur les résultats de la SA avec les dimensions fractales d'Higuchi et Katz. En (a) et (b), la dimension fractale selon Higuchi est utilisée comme fonction non-linéaire. Le graphique (a) montre les courbes avec échelle logarithmique en abscisse tandis que (b) présente le détail pour des valeurs

faibles de synchronisation avec échelle linéaire en abscisse. Les figures (c) et (d) présentent les résultats pour la SA avec la dimension fractale selon Katz comme fonction linéaire, avec échelles logarithmique (c) et linéaire (d).

Il est clair que la SA peut détecter une synchronisation des signaux. Aussi, cette détection est autrement plus sensible au fur et à mesure que la vitesse de conduction augmente. La sensibilité à la synchronisation est plus forte avec Higuchi lorsque la synchronisation est élevée ou que la vitesse de conduction est faible. Avec Katz, la sensibilité est plus élevée pour une faible synchronisation lorsque la vitesse de conduction est plus élevée. Cela montre qu'il est possible d'utiliser différentes fonctions non-linéaires de manière complémentaire pour évaluer la synchronisation.

Les résultats présentés à la Figure 4-45 sont équivalents à ceux présentés dans [FAR02], à la différence que la dimension fractale est utilisée au lieu du pourcentage de déterminisme et qu'un fenêtrage est utilisé. Les dimensions fractales d'Higuchi (a) et Katz (b), la fréquence médiane (c) et le kurtosis (d) sont données selon le taux de synchronisation pour différentes vitesses de conduction. La même fenêtre qui était utilisée pour l'analyse par la SA a été utilisée pour le calcul des fonctions non-linéaires (FD et kurtosis) et la fréquence médiane afin d'assurer une uniformité. Cependant, le fenêtrage est généralement inutile dans le cas du calcul des FD et du kurtosis. Notons que les valeurs des absolues des fonctions non-linéaires sont sans signification importante. On s'intéresse surtout à la variation des valeurs selon les différents paramètres. Dans [FAR02], aucun fenêtrage n'est utilisé. Une étude complète de l'impact du fenêtrage sur la sensibilité des caractéristiques serait appropriée.

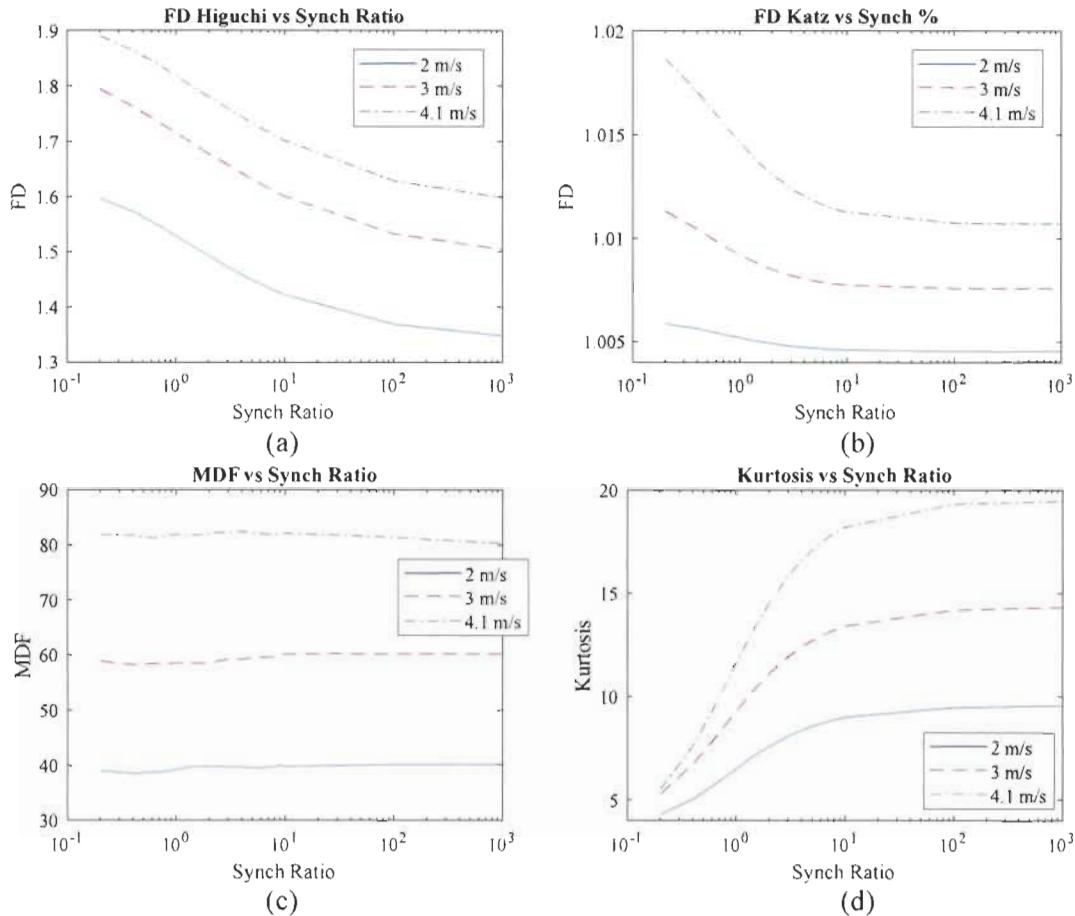


Figure 4-45 Caractéristiques moyennes selon le taux de synchronisation pour différentes vitesses de conduction.

Le graphique de la MDF montre que cette fonction linéaire n'est pas affectée par le taux de synchronisation. Par contre, la MDF est fortement influencé par la vitesse de conduction. Évidemment, plus les signaux voyagent rapidement, plus la fréquence est élevée. On a donc un effet de compression spectrale qui est bien connu de la littérature [STU81][HER92][KUP95]. Cette caractéristique linéaire peut évidemment être combinée avec des caractéristiques non-linéaires. Lorsqu'il est question d'utiliser plusieurs caractéristiques non-linéaires, il est sous-entendu « joindre plusieurs caractéristiques linéaires et non-linéaires ».

Le graphique du kurtosis montre une sensibilité intéressante. Par contre, on s'attend que pour le kurtosis, le cas présenté soit le meilleur. Pour un modèle tripolaire ou un train d'impulsion, la

sensibilité du kurtosis devrait être grandement réduite. L'intérêt d'utiliser différentes méthodes non-linéaires de manière complémentaire a été montré intéressante. De la même manière, l'utilisation d'une seule caractéristique en variant un paramètre pourrait aussi atteindre le même objectif. Par exemple, varier le paramètre α pour la dimension fractale de Katz pourrait donner plusieurs courbes complémentaires. Évidemment, plusieurs caractéristiques non-linéaires avec chacune plusieurs valeurs de paramètres est une piste de solution pour permettre l'identification du système. Une minimisation du nombre de paramètres pourrait se faire par méthode méta-heuristique, comme un algorithme génétique.

4.2.7 Variabilité des caractéristiques

La position aléatoire des signaux non-synchronisés crée une certaine variabilité des caractéristiques pour des paramètres identiques de simulation. Une évidemment, une certaine synchronisation peut se produire simplement par hasard. Cette synchronisation devrait être fonction du nombre de signaux de base utilisés pour générer le signal non-synchronisé. Dans la simulation présente, le nombre de signaux de bases était de 500, ce qui est élevé. Notons que si le nombre de signaux de base est trop faible, les signaux pourront sembler synchronisés même si les impulsions sont distribuées aléatoirement. À la limite, si le signal non-synchronisé est composé d'un seul signal de base, celui-ci sera identique à un signal parfaitement synchronisé. Il a été remarqué lors de simulations préliminaires que l'impact du nombre de signaux de base est aussi influencé par la distance entre les charges et la vitesse de conduction.

Une autre cause possible de variabilité est la présence d'effets de bord. Ceux-ci peuvent intervenir dans la variabilité de la synchronisation aléatoire, peu importe si le fenêtrage est employé ou non.

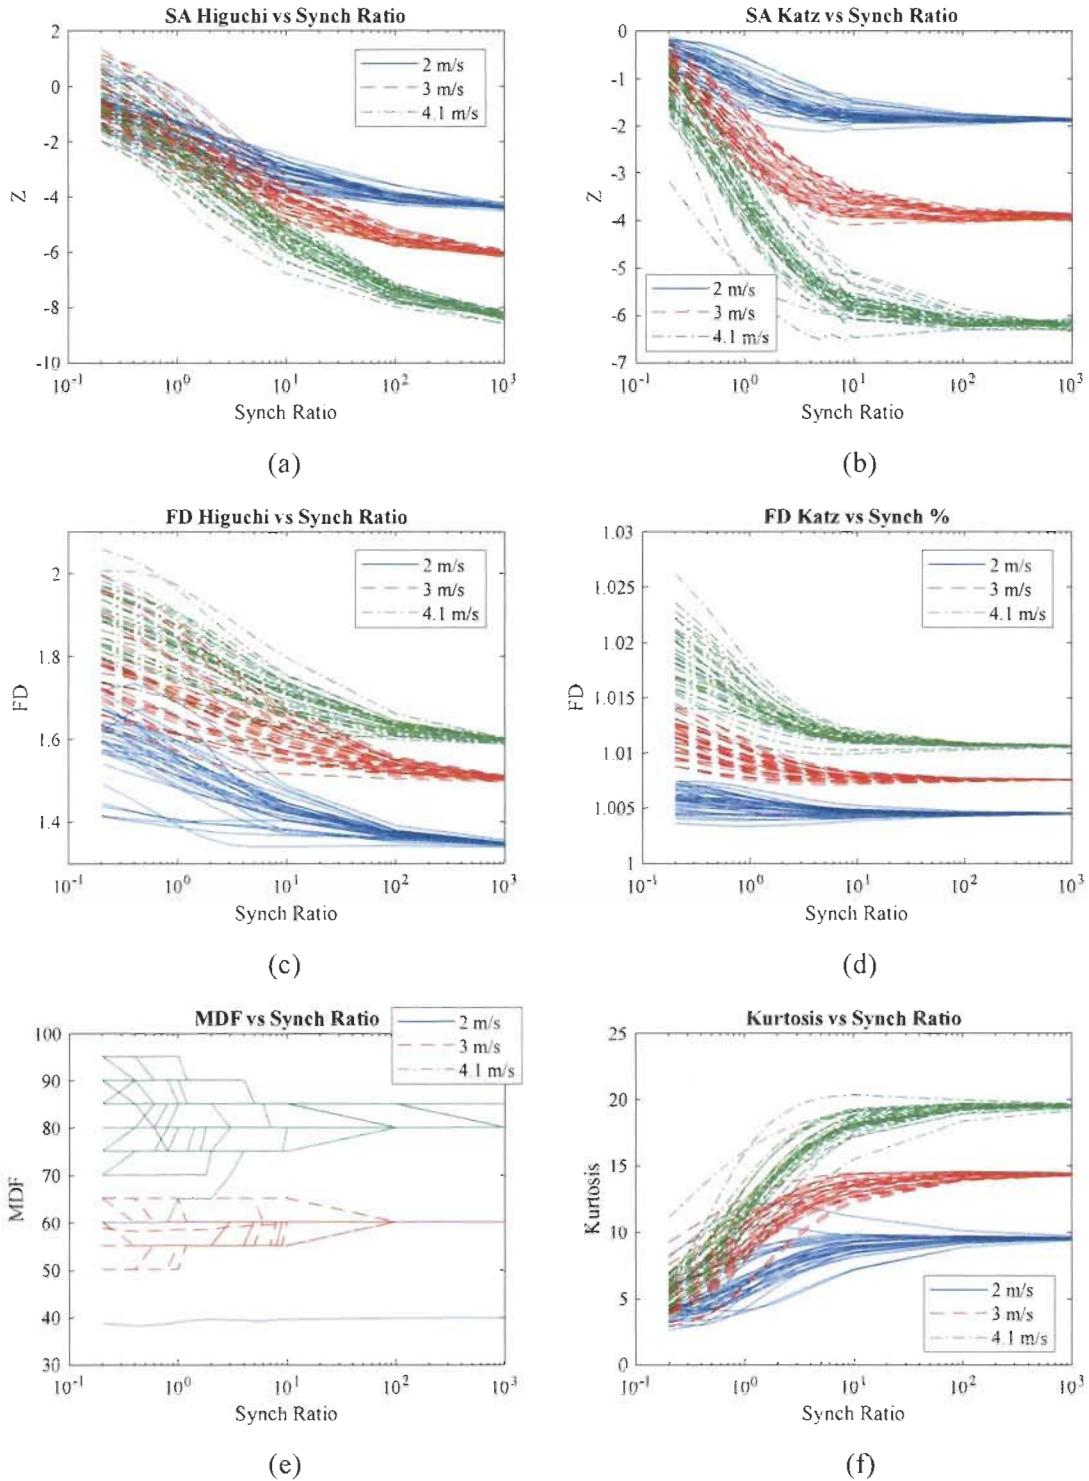


Figure 4-46 Caractéristiques selon le taux de synchronisation pour différentes vitesses de conduction

La Figure 4-46 représente les courbes obtenues pour toutes les simulations, sans faire la moyenne. Ces courbes mettent en évidence la variabilité des caractéristiques. On voit que les

caractéristiques se superposent grandement lorsque le taux de synchronisation est faible. Évidemment, lorsque le taux de synchronisation est élevé, les signaux se ressemblent plus d'une simulation à l'autre. Chaque courbe est établie à partir d'une pondération de signaux synchronisés et non synchronisés sans recalculer à chaque fois la portion non synchronisée. Bien que les graphiques auraient pu être représentées par la moyenne et déviation standard (ou valeur extrêmes), la représentation proposée, avec toutes les courbes, montre que pour un signal non-synchronisé donné, la courbe selon le taux de synchronisation suit relativement bien la tendance centrale. Notons que la fréquence médiane présentée en (e) est fortement quantifiée dû au nombre de point limité sur lequel est fait la FFT.

Il serait important d'évaluer la corrélation entre les différentes caractéristiques par rapport à cette variabilité dans l'optique de tenter d'identifier les paramètres du système. Notons aussi que la proposition de la section précédente quant à l'utilisation de plusieurs fonctions non-linéaires avec plusieurs paramètres avec optimisation par algorithme génétiques peut se généralisée aisément pour tenir compte de la variabilité discutée.

4.2.8 Perspectives

Malgré les réserves exprimées sur la possibilité d'obtenir une valeur précise du taux de synchronisation, on peut entrevoir la perspective d'étudier des tendances ou de pouvoir effectuer des comparaisons par une caractéristique obtenue par l'inversion d'une fonction qui serait extraite à partir d'un modèle simplifié. Aussi, une telle caractéristique pourrait s'avérer plus adaptée pour être interprétée que la SA. De plus, il est probable que cette caractéristique soit plus efficace que la SA, particulièrement pour les situations où peu de données sont disponibles. Cela serait dû au « pré-travail » fait à partir du model, ce qui est équivalent à une information à priori intégrée dans l'algorithme.

La possibilité d'observer une forme de synchronisation à partir d'un seul capteur est une nouveauté. Autant pour l'étude de l'EMG que de l'EEG. Bien que la synchronisation soit étudiée pour l'EMG, les signaux sont souvent étudiés pour de faibles forces, où il y a peu d'interférence. L'approche proposée permettrait de considérer la synchronisation de signaux provenant de sources très rapprochées, sous la résolution spatiale pouvant être obtenues par capteurs. Aussi, la proposition pourrait s'attaquer à des forces plus grandes sans nécessité de détection de pics. Cela permet donc d'aborder des questions de synchronisation locale et non entre deux régions distantes. Toutefois, cette approche donne une caractéristique globale, étant affectée par plusieurs fibres aux géométries, vitesses de conduction et formes d'impulsions différentes.

Malgré le caractère convolué (au sens figuré et non mathématique) de la caractéristique suggérée, il serait possible d'effectuer une cartographie de la synchronisation à partir de celle-ci. Les méthodes étudiant la synchronisation des signaux de l'EMG sont généralement effectuées par comparaison entre deux points (spatiaux). Dans le cas proposé, seulement 1 point est considéré. Malgré qu'il soit concevable d'établir une cartographie de la synchronisation en utilisant la comparaison entre différents points, il est plus naturel de le faire à partir de caractéristiques mesurées en un seul point.

Le problème de l'estimation de la synchronisation par sEMG est un problème difficile [YUE95], sensible au bruit et sujet à la fausse détection de pics dû aux formes d'ondes des potentiels d'action qui sont fortement déformées. Aussi, les études de synchronisation sont généralement limitées à une force de 30% de la force volontaire maximale (MVC) [STE00]. Même pour l'EMG intramusculaire, les forces utilisées produisent généralement une dizaine d'impulsions par seconde [DAT90].

Finalement, certaines relations entre la vitesse de conduction, la synchronisation et certaines caractéristiques non-linéaires ont été abordées dans [FAT05]. L'utilisation de la SA pourrait donner une vue plus complète de l'activité musculaire.

4.3 EFFET DU FENÊTRAGE

L'effet de fenêtrage, ou l'effet des séries de courte durée, est connu pour affecter pour influencer les résultats de la SA. Si [SUZ05] a proposé d'utiliser une méthode de fenêtrage pour atténuer le problème, il est montré ici que cette approche ne fonctionne que dans certains cas et une nouvelle méthode est proposée. Dans une publication à venir [CAZ20b], le détail de la méthode ainsi que des performances dans des contextes similaires à [SUZ05] sont donnés. Dans cette section, on effleure la méthode pour se concentrer sur des aspects qui ne sont pas déjà traités dans l'article.

L'originalité de cette section se retrouve dans 1) l'application de la fenêtre sur les données de substitution, 2) l'utilisation du SA pour le problème de détection (originalité partagée avec la section sur la détection de l'ECG), l'application de la courbe de sensibilité/spécificité (courbe ROC, de l'anglais « *Receiver Operating Characteristic* ») pour analyser les performances de la SA et 3) l'analyse de l'effet du fenêtrage sur la SA selon l'ordre du processus ARMA.

4.3.1 Méthode de fenêtrage pour la SA

La méthode de fenêtrage adapté à la SA est montrée dans cette section. L'idée est premièrement exposée, suivie de schémas explicatifs montrant la méthode et des variantes utiles à l'analyse.

4.3.1.1 Idée de la méthode de fenêtrage proposée

Lorsque les séries temporelles analysées sont de courte durée, l'utilisation de la FFT pour la génération de données de substitution crée un effet de fenêtrage important qui vient biaiser les résultats de la SA, produisant des faux positifs. Ce problème, connu dès le commencement de l'utilisation de la SA [THE92] a seulement été abordé dans [SUZ05], simplement par l'application de méthodes de fenêtrage aux données originales. Or, l'application d'une fenêtre crée un effet de non-stationnarité. Cette non-stationnarité peut être détecté par la SA [TIM98], créant aussi des faux positifs.

Dans [SUZ05], l'approche était d'essayer plusieurs fenêtres et de sélectionner celle qui vient biaiser le moins possible les résultats. Cette approche améliore certains cas où le nombre de données est vraiment court, mais plus le nombre de données s'agrandit, plus le biais augmente. À un certain point, il est préférable de ne pas utiliser de fenêtre. Or, il existe une plage de nombre de données pour laquelle le taux de faux positifs est important, avec une fenêtre ou pas.

On suggère donc une approche nouvelle pour le problème du fenêtrage. L'idée est d'appliquer la même fenêtre aux données de substitution que celle employée sur les données originales. De cette façon, le même type de non-stationnarité appliqué sur les données originales se trouvera sur les données de substitution.

4.3.1.2 Comparaison de 4 approches au fenêtrage

Présentées à la Figure 4-47, on considère 4 approches au fenêtrage dans le contexte de la SA. À la Figure 4-47 (a), c'est simplement l'absence de fenêtre, ou de manière équivalente, une fenêtre rectangulaire. En (b), on retrouve la méthode de [SUZ05] qui applique la fenêtre seulement sur

les données avant la génération des données de substitution, mais pas avant le calcul de la caractéristique de la série originale. En (c), pour complétude, les données originales sont fenêtrées. La méthode proposée se retrouve quant à elle en (d), étant équivalent à (c) mais avec fenêtrage des données de substitution. L'exemple de la figure est pour un test dit « à droite ».

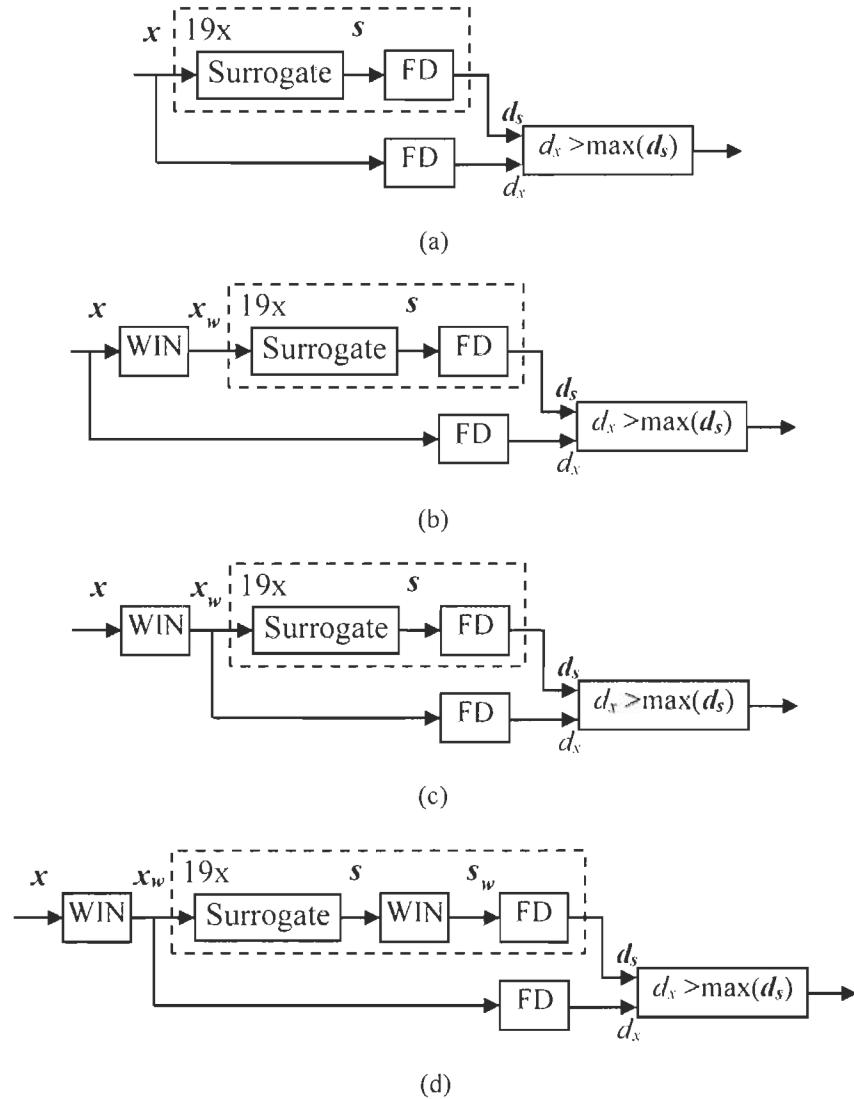


Figure 4-47 Quatre méthodes d'application du fenêtrage adapté pour la SA : a) méthode 1, b) méthode 2, c) méthode 3 et d) méthode 4.

4.3.2 Analyse des performances

Les performances des 4 méthodes seront étudiées avec une approche similaire à [SUZ05]. La version de la SA sera basée le rang. C'est le taux de faux positif qui sera mesuré lors des simulations. Avec un test basé sur le rang des caractéristiques sur 19 données de substitution, ou 39 dans le cas d'un test, on s'attend idéalement à un taux de faux positifs de 5%. Un taux plus élevé est considéré optimiste et inférieur est vu comme étant conservateur. Lorsqu'il est utilisé comme test d'hypothèse, un test conservateur permet de soutenir d'avantage le rejet de l'hypothèse nulle.

Les différents facteurs qui sont pris en compte lors des simulations sont justifiés ici.

4.3.2.1 Analyse des performances selon le type de test

Même si la majeure partie de la littérature utilise des tests d'hypothèse unilatéraux pour l'analyse par données de substitution (généralement sans en expliquer la raison), les tests bilatéraux sont particulièrement importants lorsqu'on utilise des caractéristiques non-linéaires desquels il est souvent difficile de prédire l'impact de la non-linéarité observée. Ceci est encore plus vrai lorsque la SA est utilisée lors d'exploration de données (*Data Mining*).

4.3.2.2 Choix de la fenêtre

La fenêtre suggérée par [SUZ05] offrant la meilleure performance est la fenêtre de Welch, de forme parabolique. Il y a par contre un avantage à utiliser la fenêtre de Tukey, présentée à la Figure 4-48, basée sur un cosinus modifié : la fenêtre admet un paramètre. Ce paramètre peut être optimisé selon le nombre de données, le spectre de puissance, la méthode non-linéaire

employée, le type de signal à détecter ainsi que les performances recherchées, possiblement en considérant le ROC.

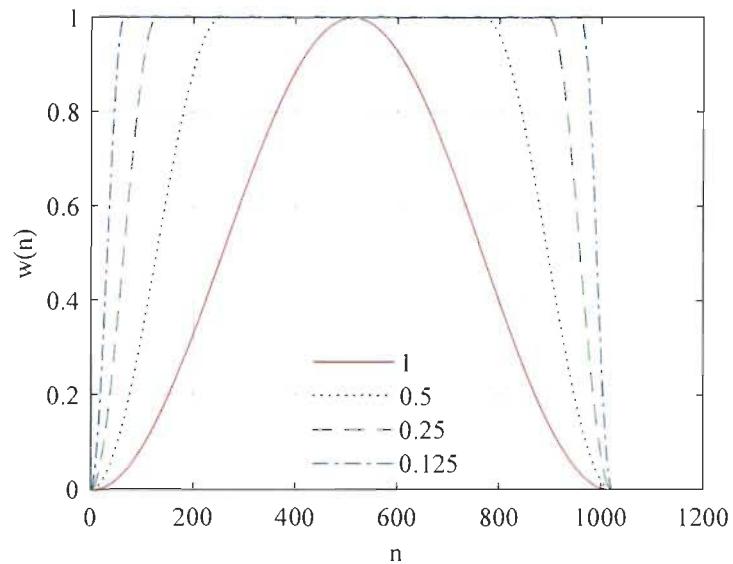


Figure 4-48 Fenêtre de Tukey pour différents paramètres

4.3.2.3 Dualité nombre de données et bande passante du signal

L’approche proposée permet de réduire les effets de fenêtrage pour les séries courtes, mais aussi des séries plus longues dont la bande passante est faible. Cette situation est très fréquente. Simplement en augmentant le taux d’échantillonnage d’une série courte, on obtient une série plus longue mais ayant une bande passante plus faible par rapport à la fréquence de Nyquist. L’utilité est donc fonction à la fois de la longueur de la série de donnée et du spectre de puissance.

4.3.2.4 Biais variant en fonction de la pente de la bande d’arrêt

La variabilité causée par l’étalement du spectre de puissance des données de substitution est généralement asymétrique, principalement causé par le fait que l’étalement du spectre vers les hautes fréquences a plus d’impact que vers les basses fréquences. Quand les pentes des bandes

d'arrêt sont faibles, l'étalement ne change que peu la fréquence de coupure. L'étalement peut même parfois créer une interférence dans la bande de transition. Par contre, lorsque les pentes des bandes de transitions sont fortes, l'étalement provoque une forte variation de la fréquence de coupure. Les caractéristiques non-linéaires étant souvent particulièrement sensibles aux hautes fréquences, et ce généralement de manière monotonique, il en résulte un biais qui est lié à l'ordre du processus ARMA.

Lorsque le fenêtrage est appliqué aux séries de substitution, il y a une interaction entre l'étalement du spectre et la corrélation de la phase qui varient tous deux pour chaque série. Un certain effet de compensation se crée lorsque l'ordre du processus ARMA est faible. Cependant, plus l'ordre est élevé, plus cette compensation est inefficace. Une explication plus poussée pour un signal de type AR(1), simulations à l'appui, se trouve dans [CAZ20b].

Il serait tentant de corriger ces artefacts en réajustant notamment les amplitudes du spectre de puissance. Or, en faisant cela détruit le fenêtrage temporel. (Note : si on applique itérativement le fenêtrage et la correction du spectre, on finit par converger à une fonction de Dirac centrée).

4.3.3 Simulation des performances sur hypothèse nulle

Des simulations sur signal stochastique construit à partir d'un bruit blanc Gaussien filtré par un filtre de Butterworth sont montrées. La fréquence de coupure (bande passante) et l'ordre du filtre sont variés. Les résultats pour les tests bilatéraux sont donnés. La fenêtre utilisée de Tukey utilisée avec différents paramètres. Le nombre de données par séries est balayé. Un délai transitoire est considéré avant la sélection des données. Pour chaque point, 5000 simulations sont faites.

4.3.3.1 Méthode 1 (sans fenêtre)

Lorsqu'aucune fenêtre n'est utilisée, les résultats se présentent aisément étant donné l'absence de paramètre de fenêtre nécessaire. La Figure 4-49 montre les résultats de la méthode 1. On observe que l'ordre du processus (du filtre Butterworth) a un impact majeur sur les résultats. Ceci est d'autant plus vrai lorsque la bande passante (BP) est faible. De plus, l'effet est plus marqué lorsque le nombre de données est limité.

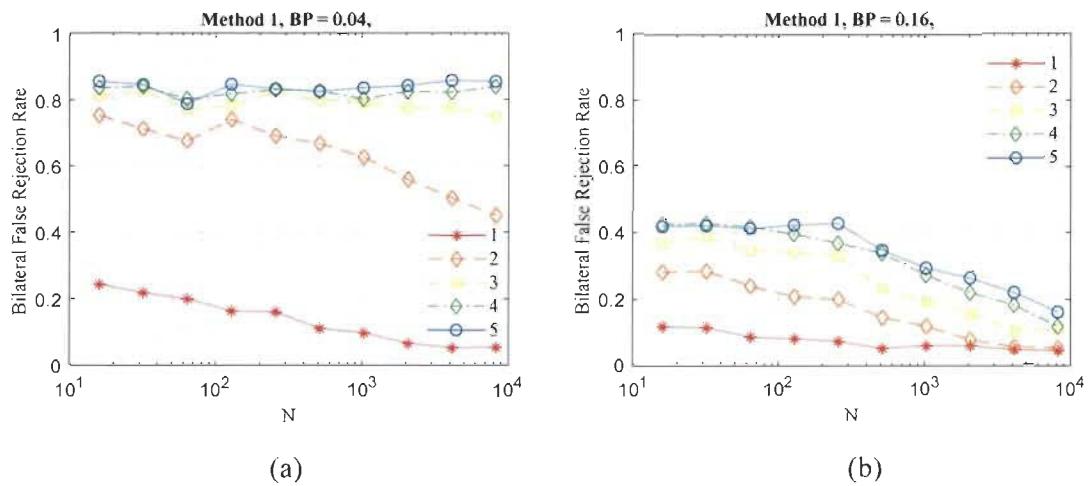


Figure 4-49 Effet du fenêtrage sur la SA selon le nombre de données avec différentes bandes passantes et ordres de processus

4.3.3.2 Comparaison des 4 méthodes, fenêtre fixe

Les méthodes 1 à 4 sont comparées à la Figure 4-50 pour deux bandes passantes et trois ordres. Le paramètre de la fenêtre est gardé fixe. La méthode 4 est généralement celle qui est la plus conservatrice. Habituellement, la méthode 3 fonctionne mieux que la méthode 2 lorsque le nombre de données est limité, tandis que le contraire est trouvé lorsque le nombre de données est grand. Aussi, il arrive dans quelques rares cas que la méthode 2 présente des résultats détériorés par rapport à la méthode 1.

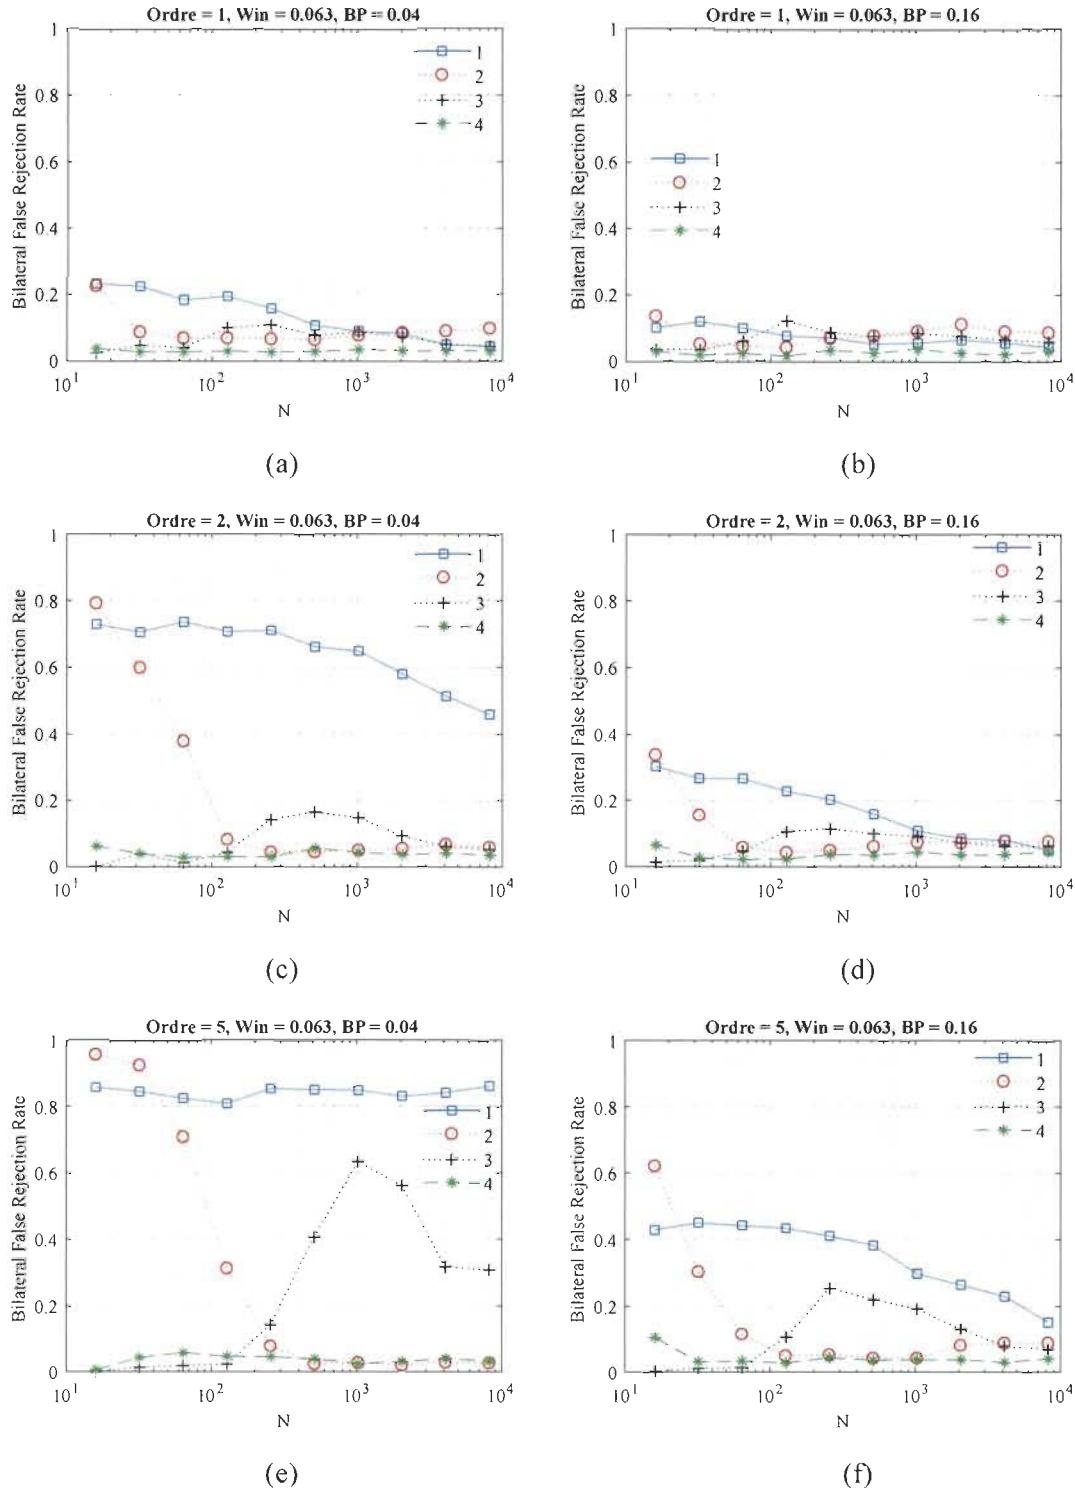


Figure 4-50 Performances des méthodes (1 à 4) de fenêtrage pour la SA, paramètre de fenêtre fixe.

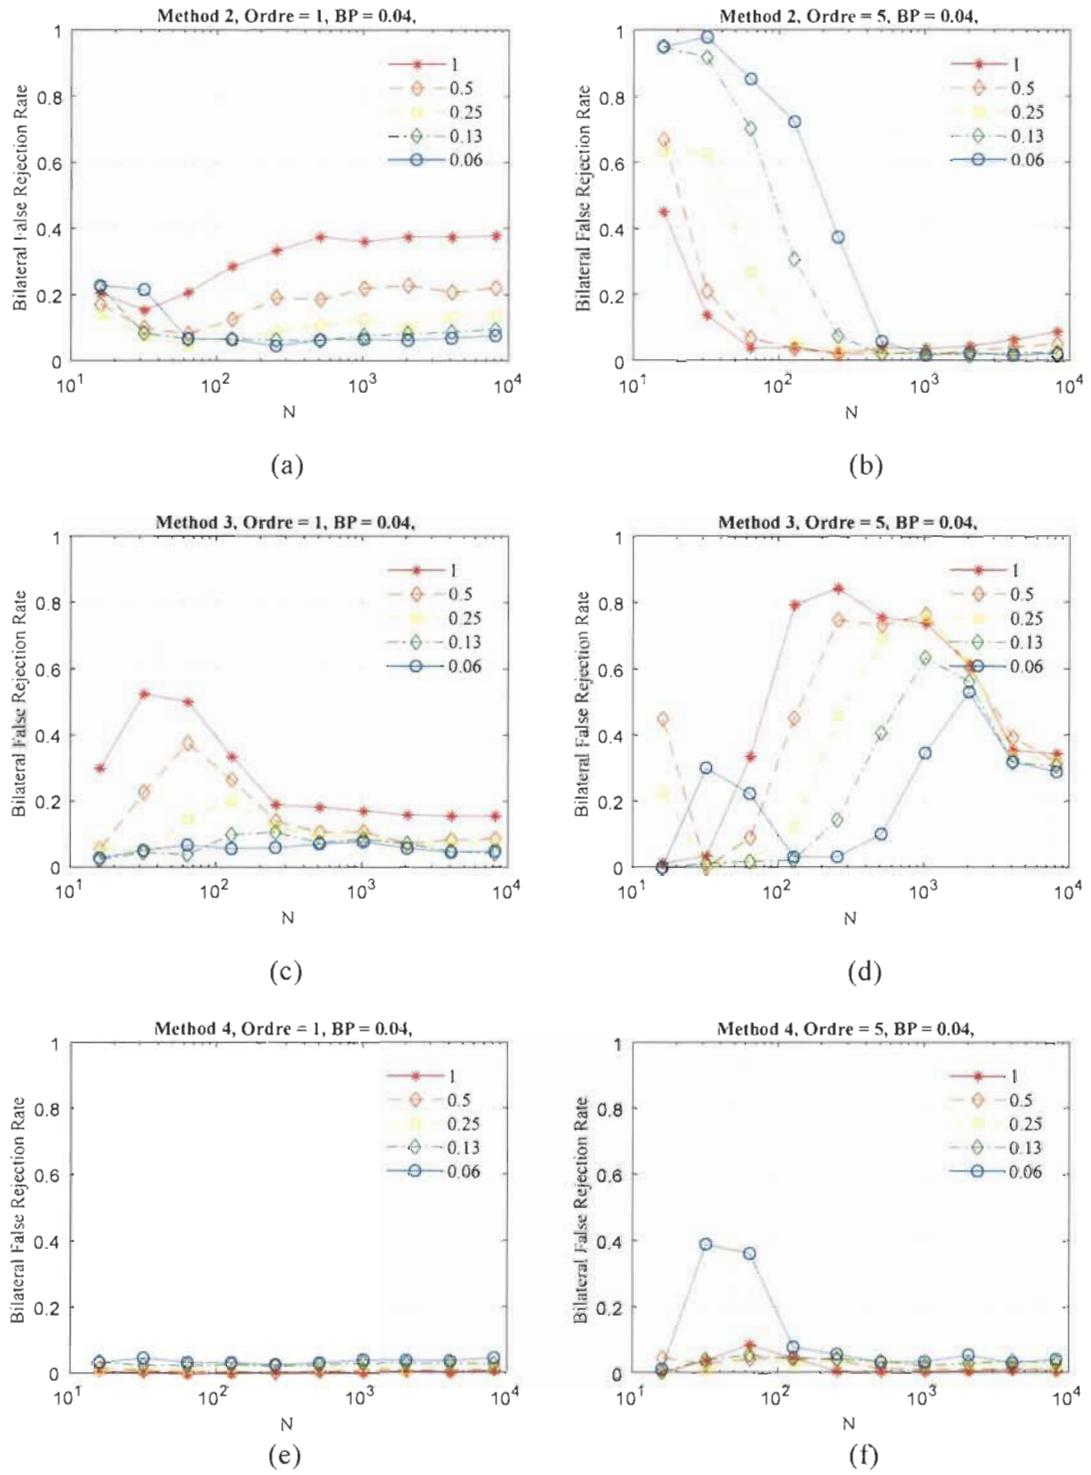


Figure 4-51 Performances des méthodes de fenêtrage pour la SA, variation du paramètre de la fenêtre (valeur en légende).

4.3.3.3 Effet du paramètre de la fenêtre, bande passante fixe

L'effet du paramètre de la fenêtre est présenté à la Figure 4-51 pour les méthodes 2, 3 et 4. Les ordres 1 et 5 sont montrés. La bande passante choisie est faible dans le but de souligner d'avantage l'effet de fenêtrage. On voit que les performances varient fortement selon le paramètre de la fenêtre.

Il n'y a clairement pas de règle générale pour le choix de la fenêtre, toute méthode confondue. La méthode 3 pour un ordre de 5 (d) a pratiquement un paramètre optimal différent pour chaque longueur de donnée. Par contre, cela signifie que c'est la forme du bord de la fenêtre qui compte. Pour un même paramètre, le bord devient de moins en moins abrupt au fur et à mesure que le nombre de données augmente.

Pour la méthode 4 avec l'ordre 1 (e), on voit que les résultats peuvent devenir trop conservateurs. Le meilleur paramètre est probablement celui qui maximise l'erreur, selon l'application.

4.3.4 Effet sur l'information

On s'intéresse à savoir si la méthode de fenêtrage a un impact important sur l'information recueillie. Pour ce faire, on examine un cas particulier où on cherche à détecter un signal non-linéaire dans un bruit (linéaire).

Il est supposé ici que plus les performances en détection seront fortes, plus la quantité d'information conservée sera grande. Cette supposition est indirecte mais semble raisonnable.

4.3.4.1 Compensation du biais causé par le fenêtrage

Avec l'approche par rang de la SA, il est possible de rendre le test plus optimiste en réduisant le nombre de données de substitutions ou en changeant le rang nécessaire pour le rejet de l'hypothèse nulle. Le rendre plus conservateur est plus difficile. La distribution des caractéristiques est relativement compacte. Les valeurs extrêmes sont donc mal représentées et le changement de rang ne permet plus de changer le seuil de rejet.

Par contre, pour un score de SA, la variable est continue et on peut corriger le biais par simple soustraction du biais moyen. Encore mieux, si l'on cherche à faire la détection d'un processus non-linéaire connu, il est possible de choisir un seuil qui optimise les performances, sans se soucier du biais exact. Le score de la SA sera plus facile à étudiée pour connaître l'impact sur la perte possible d'information causée par le fenêtrage. La Figure 4-52 présente un exemple d'histogramme des scores obtenus pour une série linéaire et une série non-linéaire (bruitée de telle sorte que les histogrammes aient un recouvrement).

Pour ces histogrammes, il est possible d'établir un seuil pour séparer raisonnablement les séries linéaires et non-linéaires. Par contre, un compromis entre faux positifs et faux négatifs doit être fait. En général, ceci est fait par l'utilisation de courbes de sensibilité/spécificité (ROC, de l'anglais *Reciever Operating Characteristic*). Avec ces courbes, on peut ajuster un seuil de détection selon les performances désirées.

Une question qui survient est de savoir s'il y a un quelconque avantage à utiliser la méthode de fenêtrage proposée dans le cas où un seuil est ajustable. Si une simple modification du seuil permet de compenser pour les effets de fenêtrage, la nouvelle méthode est peut-être superficielle. Les courbes ROC permettront d'identifier les avantages de la méthode proposée.

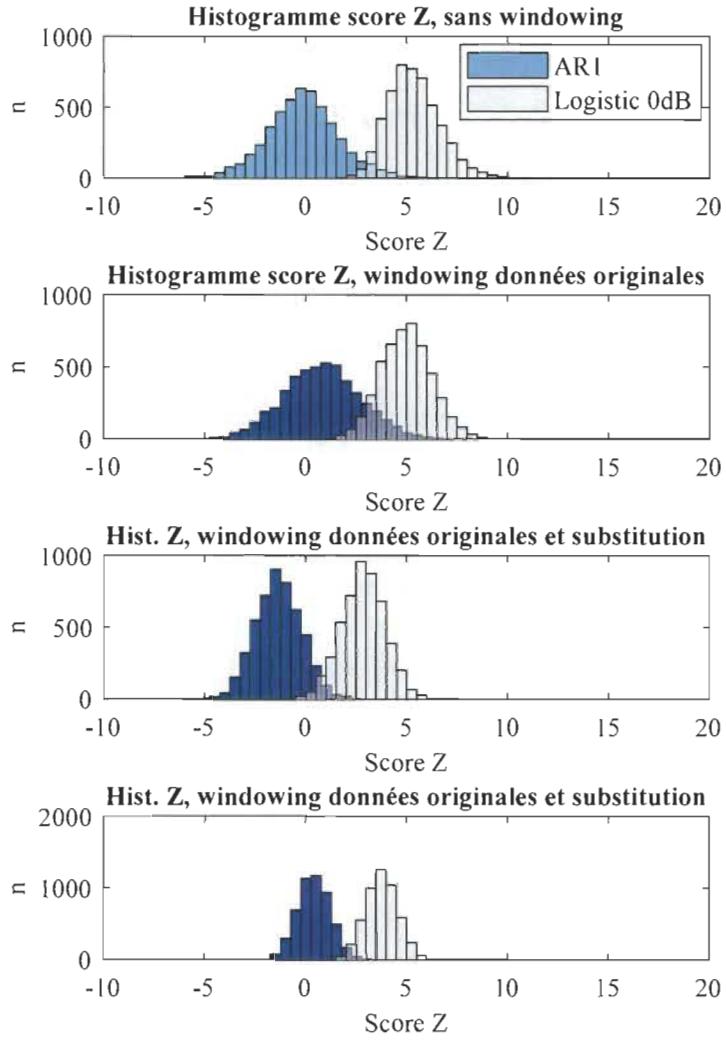


Figure 4-52 Détection de la série logistique par les méthodes 1 (haut) à 4 (bas).

4.3.4.2 Courbes ROC

Les résultats des courbes ROC sont présentés à la Figure 4-53. En (a), (c) et (e), les calculs ont été établis à partir du rang, tandis qu'en (b), (d) et (f), ce sont les scores qui sont utilisés. Les SNR sont respectivement -10, -6 et 0 dB. La fenêtre de Welch (forme parabolique) est utilisée. Le nombre d'itérations de simulation Monte-Carlo est de 5000. La série logistique a été utilisée comme série non-linéaire. Le bruit utilisé est un AR(1) avec facteur de rétroaction de 0.995, ce qui donne un bruit de type passe-bas, sensible au problème de fenêtrage.

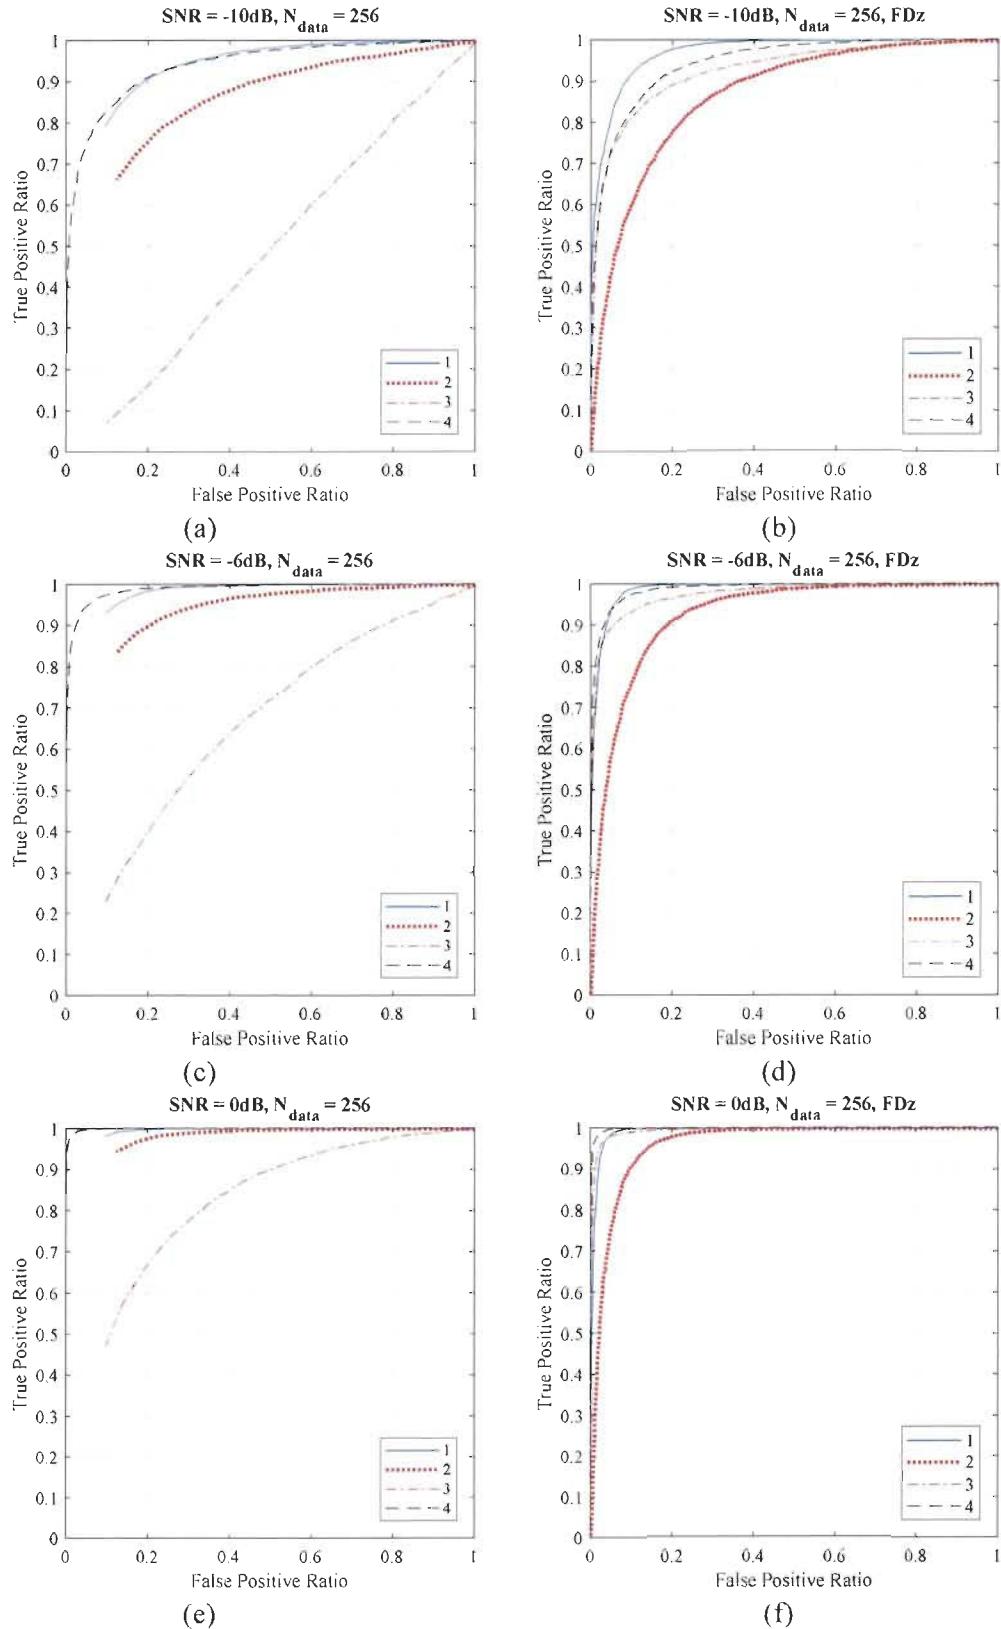


Figure 4-53 Courbes ROC de détection de la série logistique pour les méthodes 1 à 4.

La remarque la plus importante est qu'il n'y a pas une méthode dominante dans tous les cas. Particulièrement, si on s'intéresse au cas sans fenêtre (méthode 1) et la méthode proposée (méthode 4), à bas SNR, il semble préférable de ne pas utiliser la méthode de fenêtre, tandis qu'à plus haut SNR, la méthode proposée devient avantageuse. Notons cependant qu'avec une fenêtre, la méthode proposée est toujours la plus performante. Cela n'est valide que pour les séries testées. Il ne semble pas y avoir de consensus sur le choix entre la SA basée sur le rang ou sur le score en termes de performances mais on remarque qu'il est plus facile d'obtenir des courbes complètes à partir des scores, ce qui dénote une plus grande flexibilité pour le score.

4.3.5 Discussion

On mentionne ici certaines améliorations et applications pour la méthode de fenêtrage proposée.

4.3.5.1 Autres fenêtres

Beaucoup de fenêtres utilisées couramment ont été développées dans le but d'obtenir certaines performances quant à la résolution de l'estimation du spectre de puissance et non pour l'analyse non-linéaire. Les fenêtres les plus populaires n'ont donc pas *à priori* de valeurs supérieures dans le cadre de l'analyse non-linéaire.

Une étude complète du type de fenêtre à employer n'a pas été faite. De toute manière, pour chaque type de signal, une étude nouvelle serait de mise. L'optimisation d'une fenêtre ayant un paramètre devrait être suffisante pour la plupart des contextes.

4.3.5.2 Détection de la non-linéarité dans un bruit ayant le même spectre

L’analyse de l’information par courbes ROC a été faite avec une série non-linéaire et un bruit de spectre relativement différent. Il est concevable que la détection par SA soit d’une importance particulière dans le cas où le bruit est de spectre similaire au signal désiré car dans ce cas, cela rend inutile un grand nombre de méthodes de filtrage linéaires. Pour étudier ce cas, l’utilisation des données de substitution pour la simulation d’un bruit de même spectre serait préférée, avec peu de travail pour obtenir des effets de bord réalistes. Aussi, pour avoir un meilleur contrôle sur la bande passante du signal non-linéaire, étudier un système à temps continu, comme par exemple le système de Rössler serait probablement préférable.

4.3.5.3 Importance des séries de courte durée dans le cadre de caractéristiques pour classification

En plus d’apporter une meilleure compréhension de l’interaction entre le fenêtrage et la SA, les travaux permettent d’approcher des séries de courte durée. Ceci arrive souvent dans le cas où des réponses en temps réel sont désirées. Le prochain chapitre présente donc un exemple d’application de la méthode de fenêtrage développée.

Chapitre 5: APPLICATION DE LA SA À LA CLASSIFICATION DE MOUVEMENTS PAR SEMG

Ce chapitre montre que la SA peut être appliquée à la détection de mouvements par matrices sEMG. Ainsi, cela ouvre la porte à considérer la SA comme une méthode pouvant s'utiliser dans une multitude de contextes, étendant la portée de la thèse.

Idéalement, on aimerait montrer que la SA donne de meilleures performances que tout ce qui est existant pour cette application. Cependant, les résultats montrent que c'est loin d'être le cas. On aimerait trouver que la SA vient compléter d'autres méthodes pour permettre d'augmenter les performances. De ce côté aussi ce n'est pas concluant. Du côté de la SA, on se contentera de montrer qu'il y a un certain niveau de performance atteint et donc qu'il y a de l'information incluse dans la caractéristique. Ce dernier aspect est par contre important, ouvrant la porte à une multitude de caractéristiques, chaque caractéristique non-linéaire pouvant être accompagné d'un score de SA.

En même temps que de produire des résultats pour la SA, il y a eu des avancées de faites concernant l'utilisation de la FD et sur la méthodologie lors d'entraînement de réseaux de neurones dans le contexte d'identification de mouvement.

Le chapitre montrera une revue de la littérature visant les particularités des travaux présentés, le sujet de la détection de mouvement n'étant pas central à la thèse. Puis, les données sont présentées en incluant les différents prétraitements qui leurs sont appliquées. Une attention particulière vise la détection du mouvement de repos. Il est montré que celui-ci peut être traité indépendamment. Ensuite, les systèmes numériques utilisés pour faire la classification des mouvements est détaillé, notamment avec les caractéristiques choisies. Des détails

méthodologiques sont inclus. Les résultats rigoureusement non-biaisés par multiples essais sont montrés suivis de résultats de post analyse permettant d'indiquer des améliorations possibles ainsi que de mieux comprendre les performances obtenues. Le tout est conclu par une brève discussion mettant en perspective les résultats par rapport à la littérature.

5.1 BRÈVE REVUE DE LA LITTÉRATURE

Plusieurs publications font une revue de la littérature assez complète (e.g. [GEN16][NOU20]). Sans retranscrire ce qui existe déjà, les généralités s'appliquant aux points discutés dans ce chapitre sont soulignées. Un détail dont une attention particulière n'a pas été donnée par les revues de littérature disponibles a trait à la validation croisée. Cela permet de comparer les performances atteintes à celles de la littérature sur une base égales.

Les performances liées à la détection de mouvements dans la littérature nécessitent une interprétation au-delà du simple taux de succès annoncé. Plusieurs aspects peuvent affecter les résultats, à commencer par le choix d'un groupe de test. Il y a deux principales approches utilisées dans la littérature pour faire des groupes de tests :

- 1) Les groupes tests ont été faits dans une autre séance (une autre journée) que les groupes d'entraînement,
- 2) Les groupes tests ont été faits dans une la même séance que les groupes d'entraînement.

Lorsque les groupes de tests sont produits après les groupes d'entraînement, les performances obtenues sont représentatives de la prédiction. Par contre, pour augmenter le nombre de données artificiellement, il est fréquent d'utiliser des méthodes de validation croisée. Or, ces méthodes font que l'on cherche à « prédire » des événements en connaissant le passé et le futur. Dans le cas où les essais se font sur différents jours [CHA07][NOU20], l'impact est probablement

négligeable. Par contre, si cela est fait sur des mesures rapprochées, il y a un risque important de fausser les résultats en faisant une interpolation au lieu de prédiction. Cette situation se trouve dans la plupart des publications ayant trait à la détection de mouvements par EMG [DAL12][COE14].

Par contre, étant donné la diversité des détails méthodologiques de ces publications et la difficulté à prédire l'impact de ces choix sur les résultats, la critique de l'approche par validation croisée se doit d'être tempérée. Aussi, étant donné que certains résultats pratiques sont atteints, il y a certes un certain niveau de performance réel [NOU20]. Bien que la problématique liée à la validation croisée ne soit pas utilisée pour réduire les performances obtenues dans la littérature, une étude sommaire de l'impact de ce choix sur la série de donnée employée est faite ici. Le nombre de mouvements est très variable d'une publication à l'autre. Évidemment, des performances sur un nombre limité de mouvements [CHA07] sont difficilement comparables à celles présentées sur plus de 50 mouvements [GEN16].

On trouvera les performances les plus élevée tournant autour des 98% [COE14] pour la reconnaissance de 7 mouvements à l'aide de la FD évalué à partir d'une méthode de validation croisée sur une même séance. Il est aussi montré dans [GEN16] que des traitements peuvent être appliqués après les méthodes de classification (e.g. vote majoritaire) pour améliorer les performances de leur système à 99% de succès (basé sur la validation croisée). Pour les données présentées ici, [NOU20] atteint 97% de succès en validation croisée. Avec d'autres sujets, pour 10 mouvements mais en validant de manière causale, encore une fois 97% de succès est atteints.

On voit donc que des taux de succès très élevés ont été atteints dans la littérature. Il sera difficile de dépasser ces taux, surtout de manière statistiquement significative. Par contre, atteindre des

performances similaires avec des caractéristiques différentes peut être intéressant. Des caractéristiques différentes peuvent souvent être combinées pour obtenir de meilleurs résultats.

Les travaux présentés dans [COE14] montrent les performances de différentes méthodes fractales pour la reconnaissance de 7 mouvements et seulement 8 capteurs sont utilisés. Les performances sont établies par validation croisée stratifiée. Notamment, la méthode de Katz atteint des taux de succès près de 98%. Ces de ce papier qu'il est particulièrement nécessaire de différencier avec les travaux présents. Si la SA a été utilisée pour identifier la présence de non-linéarité de l'EMG [LEI01], elle n'a pas été associée à la problématique de la détection de mouvement.

5.2 CONTRIBUTIONS

Si l'utilisation de méthodes fractales pour la reconnaissance de mouvements a déjà été présentée, elles l'étaient séparément. Ici, les méthodes sont utilisées conjointement. De plus, malgré leur corrélation avec la MDF, elles sont utilisées avec elle. Ces deux aspects sont originaux. Niveau méthodologique, la validation croisée des performances de la détection de mouvement par réseau de neurones est analysée. Il est montré qu'il est préférable que la répartition des données en groupes entraînement, validation et test soit faite par bloc, mais que l'ordre des groupes entraînement et validation devraient être inversé. L'étude est surtout conceptuelle, mais concluante. Il est montré que le mouvement de repos peut être traité individuellement.

La SA utilisée comme caractéristique discriminante pour la détection de mouvement est aussi une nouveauté. Bien que la SA ne soit pas particulièrement performante, elle l'est suffisamment pour indiquer la présence d'information. L'union des scores de la SA des FDs selon Higuchi et

Katz ont été montrées complémentaire pour l'application. Toutefois, l'addition de l'information de la SA n'a pas pu améliorer de manière significative les résultats des autres méthodes.

5.3 DONNÉES ET PRÉTRAITEMENT

Les données utilisées sont détaillées avec les prétraitements associés.

5.3.1 Description des données

Les données traitées ont été prises sur un seul sujet, étant donné la nature préliminaire des travaux. Par contre, c'était un « super sujet! » Étant donné qu'il allait publier lui-même sur ces prises de mesures [NOU20], il était prêt à passer plus de 3 heures à refaire la même chose, 51 fois de suite. Malgré le petit nombre de sujet (!), beaucoup d'information peut être extrait de ces expérimentations.

Comme suggéré, 51 expériences consécutives réparties en fichiers indépendants contenant 15 mouvements dans un ordre aléatoires séparés par un mouvement 0 ont été générés. Par rapport à [NOU20], les mouvements sont notés de 0 à 15, 0 étant le repos, au-lieu de 1 à 16 avec 1 pour repos. Notons que l'heure exacte de prise de mesures des 51 fichiers n'est pas clairement indiquée. Les données ont été mesurées à partir d'une matrice de 64 capteurs sEMG en mode monopolaire à une fréquence de 2048 échantillons par secondes. Les mesures ont été très régulières au niveau temporel d'un fichier à l'autre. La Figure 5-1 montre un exemple de canal mesuré. En (a), la mesure monopolaire est montrée, avec une mise à l'échelle arbitraire, tandis qu'en (b) les mêmes données avec un différentiel spatial, simulant des données bipolaires est donné.

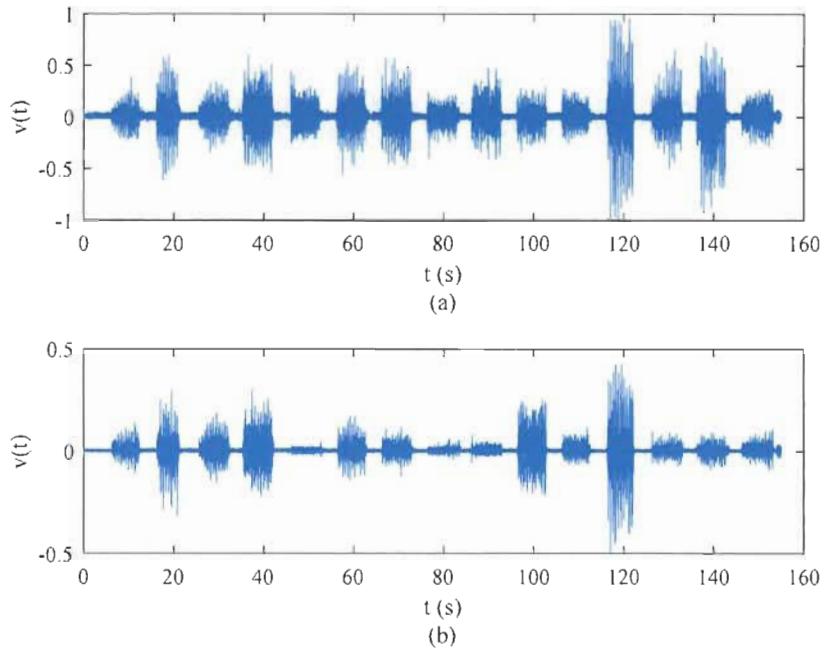


Figure 5-1 Exemple d'un canal sEMG monopolaire et avec différentiel simulé

5.3.2 Absence de préfiltres

Étant donné les spectres de puissance des signaux, le retrait du PLI (*Power Line Interference*) n'a pas été nécessaire. À la Figure 5-2 (a), on voit le spectre de puissance pour un signal monopolaire. Aucun pic n'est évident. C'est encore plus vrai pour le signal bipolaire. Un retrait du PLI pourrait améliorer certains résultats, mais l'interaction du filtrage avec les caractéristiques non-linéaires reste à vérifier. Aucun filtrage n'a été appliqué pour augmenter le SNR, encore une fois pour éviter une interaction fortuite avec les caractéristiques non-linéaires.

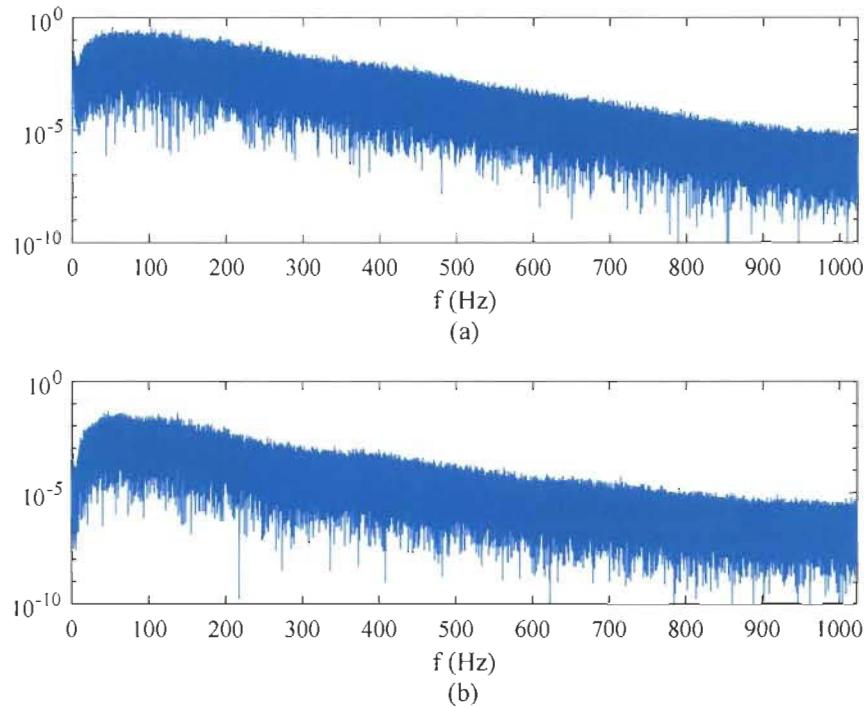


Figure 5-2 Spectres de puissances des signaux sEMG monopolaire et avec différentiel simulé

5.3.3 Filtrage spatial

Afin de réduire la corrélation entre les mesures de capteurs rapprochés spatialement, une différentiation spatiale basée sur le numéro de canal est faite. Cela réduit aussi l'impact de d'autre artéfact comme l'ECG et le PLI.

D'autres méthodes de filtrage spatial pourraient être utilisées, générant ainsi plusieurs canaux sur lesquels les caractéristiques seraient mesurées. Pour les caractéristiques linéaires, toutefois, le gain serait probablement faible, l'information nouvelle étant limitée. Il y a plus de chances d'extraire une nouvelle information pour les caractéristiques non-linéaires. Un exemple de signaux ayant un différentiel spatial était montré à la Figure 5-1 (b).

5.3.4 Fenêtrage des données

Les données ont été séparées temporellement par fenêtres de 256 échantillons. Pour réduire les effets de bords, la méthode de fenêtrage de Tukey a été utilisée avec un paramètre de 0.2. La méthode présentée dans [CAZ20b] a été utilisée pour les scores de SA. Les fenêtres sont utilisées sans recouvrement. Un recouvrement permettrait d'obtenir plus de points de mesures, mais sans nécessairement augmenter la signification statistique des résultats. Des fenêtres plus grandes pourraient aider l'estimation des caractéristiques, particulièrement pour les caractéristiques non-linéaires, mais rajouterais un délai et augmenterais le risque d'être affecté par une non-stationnarité. Pour chaque changement de mouvement, un élagage de 5 fenêtres est fait. Avec les paramètres sélectionnés, 40 fenêtres consécutives par mouvements sont obtenues.

5.3.5 Mouvement 0 (repos)

Le mouvement « repos », appelé mouvement 0 dans les données traitées, peut être traité individuellement. En effet, le problème peut se résoudre simplement par un seuil de la variance des signaux avant le calcul du filtrage spatial (avant le différentiel) comme vu à la Figure 5-1 (a). Aussi, la MDF peut à elle seule identifier le repos, comme montré à la Figure 5-4. Les fenêtres dont le signal à une MDF de 300 Hz est composé principalement d'un bruit de fond. À partir d'un seul capteur, il est déjà possible de faire une détection raisonnable. Il est donc justifié de conclure que ce mouvement peut être retiré de l'analyse. Pour confirmer la possibilité de faire une séparation adéquate, des courbes ROC utilisant un seuil sur la médiane entre tous les capteurs de la variance d'une fenêtre de 256 points sont montrées à la Figure 5-3. Ces courbes sont différencierées par le retrait de périodes de transition. On remarque que plus de données sont retirées aux transitions plus le taux d'erreur diminue, asymptotiquement vers une erreur nulle. Cela signifie que l'erreur résiduelle est concentrée aux transitions et qu'un compromis

délais/performance est possible. Notons que l'impact d'une erreur de détection de la présence d'un mouvement est simplement un retard supplémentaire. Selon les résultats, il est possible avec un retrait de 5 fenêtres d'obtenir simultanément 1% d'erreur sur la détection de mouvement et 0.67% sur le mouvement 0. De plus, il est probable que cette erreur résiduelle soit en réalité causée par le mouvement même qui est décalé par rapport au mouvement cible. C'est donc un retrait de 5 fenêtres qui sont considérées. Une comparaison avec un retrait de 10 fenêtres retirées aux transitions pour la classification des mouvements n'a pas donné d'amélioration notable. La détection du mouvement 0 n'est pas considérée dans la suite des résultats présentés. L'ajout des performances de détection du mouvement 0 viendrait clairement améliorer les résultats. L'ajout des performances lors des transitions pourrait dégrader les résultats. L'utilisation de l'aire sous la courbe ROC (AUC) n'apporte pas d'information supplémentaire.

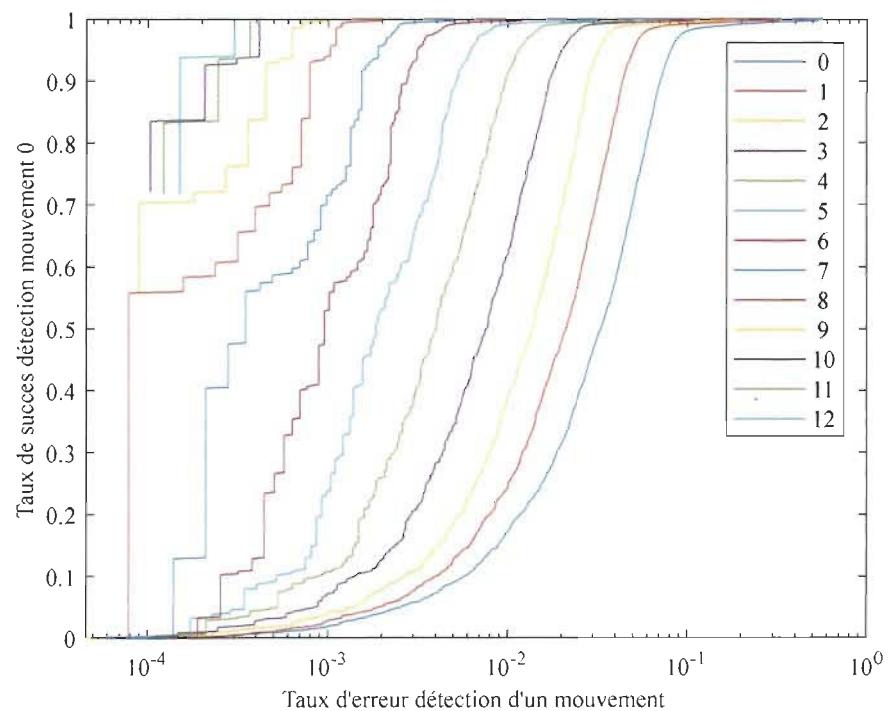


Figure 5-3 Courbe ROC de la détection du mouvement 0, différent nombre de fenêtres transitoires.

5.4 SYSTÈMES ET MÉTHODOLOGIE

Les systèmes utilisés sont décrits ici, accompagnés de diverses considérations techniques et méthodologiques.

5.4.1 Caractéristiques utilisées

Les caractéristiques utilisées sont :

- 1) Variance
- 2) Fréquence médiane
- 3) Dimension fractale d'Higuchi
- 4) Dimension fractale de Katz
- 5) Score de la SA de la FD d'Higuchi
- 6) Score de la SA de la FD de Katz

La déviation standard aurait pu être utilisée à la place de la variance, mais étant donné l'utilisation du réseau de neurones, il n'est pas très intéressant de s'intéresser à la différence entre les deux caractéristiques. Ayant montré le lien entre la MDF et les méthodes FD, il a semblé logique d'utiliser la MDF comme caractéristique représentant le spectre de puissance. Bien que d'autres méthodes fractales aient été utilisées pour la détection de mouvement [COE14], les méthodes choisies ont été montrée ayant une bonne probabilité de complémentarité [CAZ20].

D'autres méthodes classiquement utilisées avec l'EMG sont trouvées dans [HUD93]. Elles n'ont pas été utilisées puisqu'elles sont probablement très corrélées avec la MDF. Par contre, la longueur de courbe (*waveform*) est non seulement liée à la MDF mais aussi à la FD selon Katz, selon le paramètre de la méthode. Son introduction serait probablement redondante.

Un exemple des caractéristiques d'une expérience (fichier) sont montrées temporellement pour un capteur (avec différentiel spatial) à la Figure 5-4, avec les numéros de mouvements. À la Figure 5-5, les fenêtres du mouvement 0 (repos) et lors des transitions sont retirées.

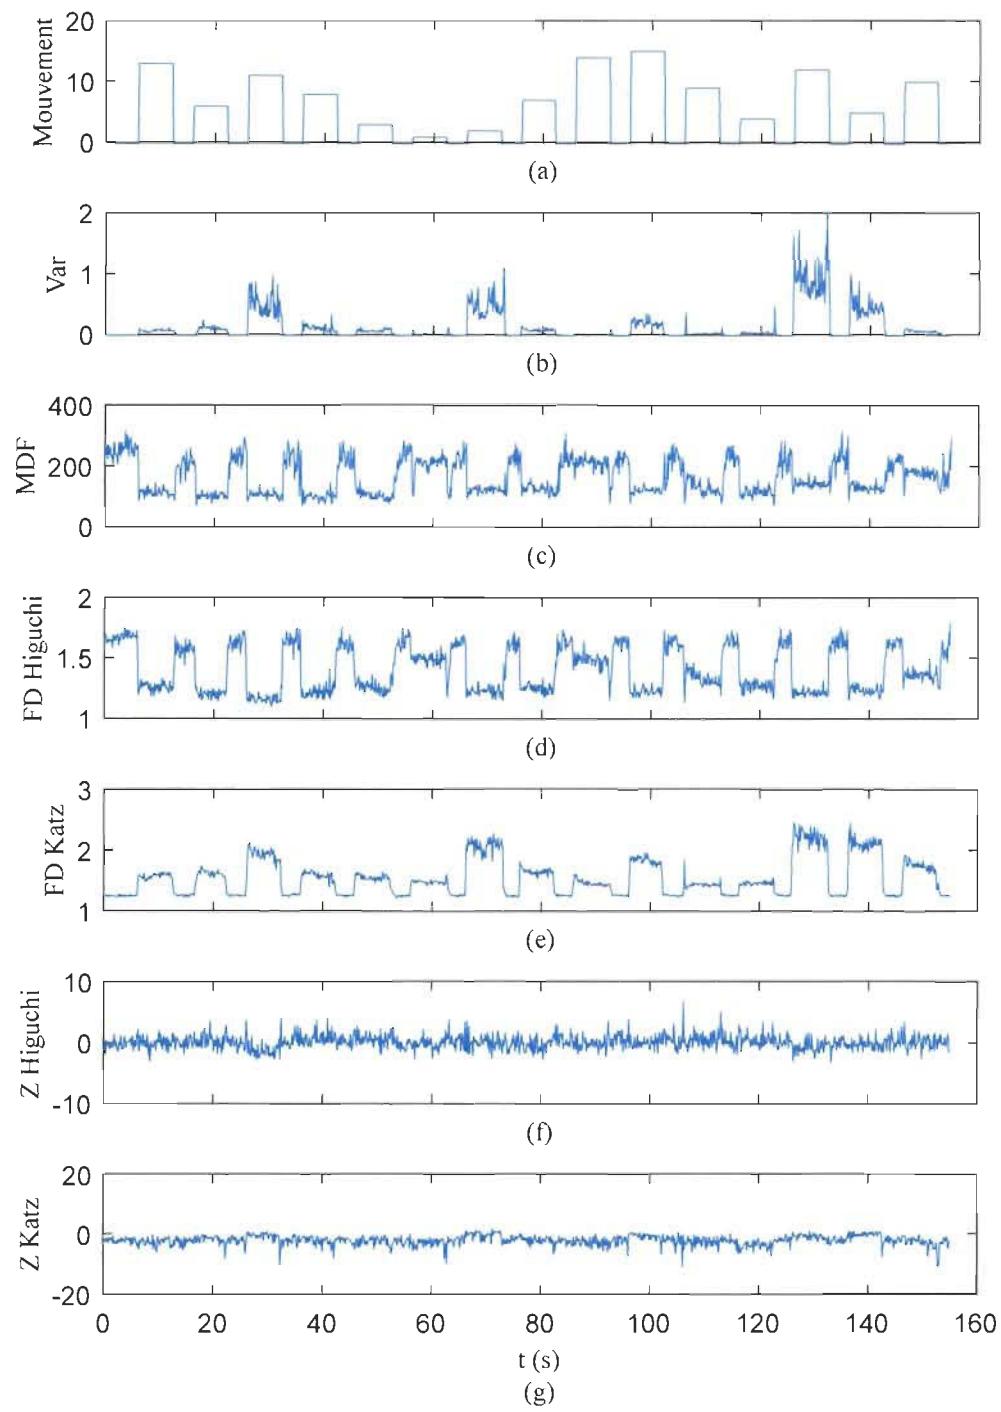


Figure 5-4 Exemple de caractéristique de signaux selon le temps pour un capteur avec mouvement 0.

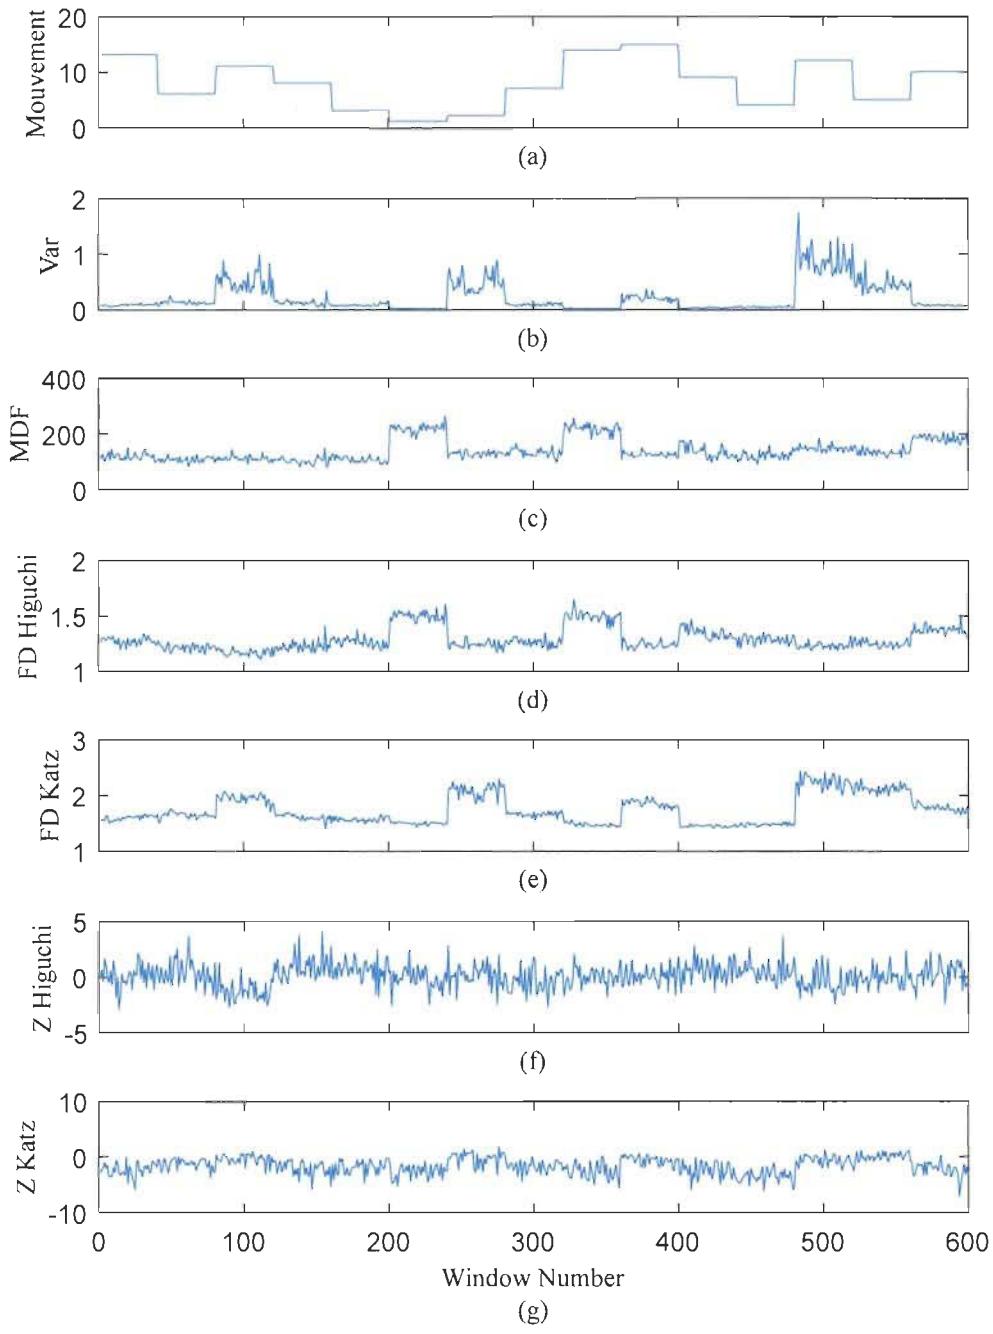


Figure 5-5 Exemple de caractéristique de signaux selon le temps pour un capteur sans mouvement 0.

5.4.2 Paramètres des méthodes fractales

Le calcul de la FD selon Katz utilise un paramètre alpha de 1. Étant très fort, la FD obtenue devrait être plutôt liée à la longueur de courbe qu'à la FD obtenue par Higuchi. Pour la FD selon Higuchi, une valeur de 5 a été choisie pour le paramètre kmax. On note que les paramètres des

méthodes de calcul de FD ont été sélectionnés grossièrement, sans optimisation. Cela laisse donc présager que les résultats présentés sont conservateurs.

5.4.3 Algorithme de classification utilisé

On retrouve comme méthode de classification appliquée à la détection de mouvement l'analyse linéaire discriminante (LDA) [CHA07][DAL12][NOU20], la Classification Bayésienne Naïve [AMM15][COE14], le modèle de mélange gaussien (GMM pour *Gaussian Mixture Model*) [HUA05] et les réseaux de neurones [WEI16]. Les algorithmes de classification sont souvent bien moins importants que les caractéristiques employées [NOU20].

Le choix du réseau de neurones a été fait parce qu'il n'est pas possible de savoir à priori si les relations entre les nouvelles caractéristiques et les classes sont linéaires. L'idée d'essayer des méthodes linéaires en premier et suivre par des méthodes non-linéaires déduit la signification statistique des résultats. La possibilité d'utiliser la méthode d'arrêt permet de contrer le fléau de la dimensionnalité de manière aisée sans recours aux méthodes de réduction de la dimensionnalité. Les méthodes de réduction de la dimensionnalité telle l'analyse en composantes principal (ACP ou PCA en anglais) ont comme défaut de possiblement détruire les relations non-linéaires si elles sont utilisées sur les données brutes et sont calculées implicitement par le réseau de neurones si elles sont appliquées après le calcul des caractéristiques si la réduction est réellement utile. La Figure 5-6 présente un exemple de réseau de neurones utilisé.

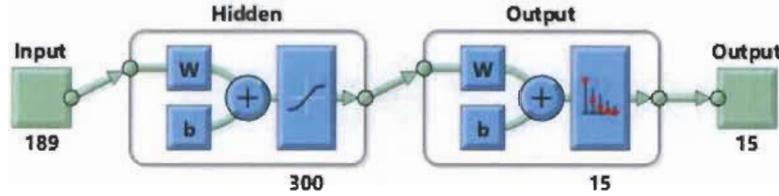


Figure 5-6 Exemple de réseau de neurone employé pour la détection de mouvement

5.4.4 Nombre de neurones

La structure et le nombre de neurones a été sélectionné de manière à rester constant pour toutes les entrées tout en étant apte à extraire la majeure partie de l'information. Après plusieurs essais préliminaires (sans utiliser le groupe de test), une seule couche cachée composée de 300 neurones a été sélectionnée. Il est évident que cette structure n'est pas optimale pour toutes les entrées, mais la sous-optimalité se retrouve surtout au niveau de temps d'adaptation, ce qui peut être ajusté une fois les entrées sélectionnées. Notons que le nombre de neurones pourrait être réduit selon le choix des caractéristiques.

5.4.5 Initialisations multiples des poids du réseau de neurones

Il y a toujours un risque avec les réseaux neuronaux qu'un minimum local soit atteint lors de l'étape d'apprentissage. Une solution simple à ce problème est d'entraîner plusieurs fois le même réseau, avec les mêmes données. On peut alors choisir un réseau dont les performances sont les meilleures. Par contre, la sélection doit se faire avant l'utilisation du groupe de test. Pour les résultats principaux, 30 essais ont été faits pour chaque réseau et celui ayant les meilleures performances sur le groupe de validation a été retenu. La Figure 5-7 présente le taux d'erreur du groupe de validation selon le rang pour toutes les entrées sans le mouvement 2. On voit clairement que pour les rangs élevés, plusieurs courbes changent drastiquement, indiquant l'atteinte d'un minimum local lors de la phase d'adaptation. C'est ce dernier dont les

performances sont évaluées sur le group test. Pour les autres résultats, seul 3 initialisations ont été essayées. Un système temps réel aura probablement une limite sur le nombre possible d'initialisations. Toutefois, cet aspect peut être aisément parallélisé du point de vue implémentation. De plus, 30 initialisations était probablement exagéré et pourrait être réduit de beaucoup.

Le choix du meilleur résultat par rapport à la validation n'est aucunement une garantie que ce soit le meilleur réseau. Par contre, cela réduit substantiellement le risque de sélectionner un réseau problématique.

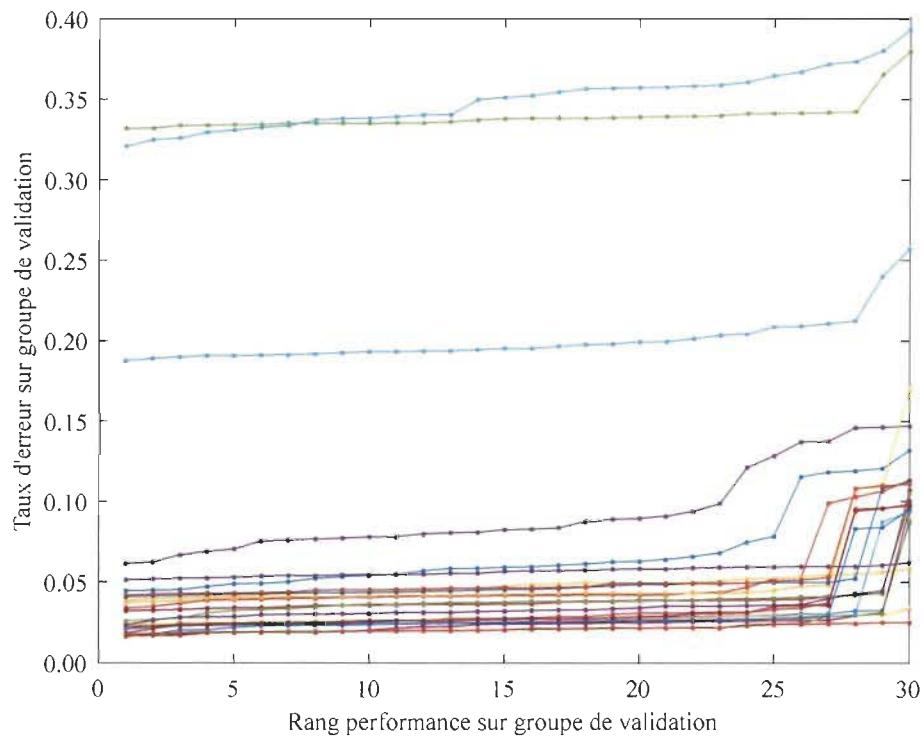


Figure 5-7 Performances pour différentes initialisations

5.4.6 Problématique des mouvements 2 et 8

Dès les tests préliminaires, il était évident qu'il y avait une difficulté à séparer les mouvements 2 et 8. Cela se voit par la matrice de confusion. Un exemple est présenté à la Figure 5-8. Le

mouvement 2 est interprété 37% du temps comme étant le mouvement 8. L'inverse n'est pas vrai.

Deux explications sont possibles :

- 1) Le mouvement 2 et 8 sont trop similaires,
- 2) Le sujet faisant les mouvements produits se trompe.

Dans tous les cas, il est pertinent de produire les résultats avec et sans un des deux mouvements.

Puisque le mouvement 8 est généralement correctement identifié, c'est le deuxième qui est retiré. Une étude plus approfondie de la différence entre les deux mouvements demeure nécessaire. Il est important de souligner que non seulement l'algorithme de classification doit être entraîné, mais aussi l'utilisateur!

339	0	0	0	0	2	0	0	0	0	7	0	12	0	0	360
0	218	0	0	0	0	0	133	1	0	0	8	0	0	0	360
0	0	359	0	0	0	0	0	0	0	0	0	0	1	0	360
0	0	0	355	0	0	0	0	0	0	4	0	1	0	0	360
0	6	2	2	347	0	1	0	0	0	0	0	2	0	0	360
1	0	1	1	0	350	4	1	0	0	0	1	0	1	0	360
4	0	0	0	0	0	356	0	0	0	0	0	0	0	0	360
0	5	0	0	0	0	0	355	0	0	0	0	0	0	0	360
0	1	0	0	0	0	0	0	355	4	0	0	0	0	0	360
0	0	0	0	0	8	0	1	11	337	1	2	0	0	0	360
2	0	0	0	0	0	0	0	2	11	339	1	0	4	1	360
10	0	0	0	0	0	0	0	4	10	0	334	0	2	0	360
3	0	0	0	0	0	0	0	0	0	4	0	347	3	3	360
0	0	0	0	0	0	0	0	0	0	0	2	0	357	1	360
0	0	0	0	0	0	0	0	0	0	0	0	0	1	359	360
359	230	362	358	347	360	361	490	373	362	355	348	362	369	364	5400

Figure 5-8 Matrice de confusion, problème du mouvement 2

5.4.7 Utilisation du filtre médian

Le filtre médian permet d'utiliser plusieurs résultats consécutifs pour extraire une meilleure estimation lorsqu'il est prévu que le mouvement soit identique pendant une certaine période de

temps. Ce filtre a un impact similaire au choix majoritaire utilisé notamment dans [GEN16]. Ce sont par contre des valeurs probabilistes (*soft outputs*) qui sont affectées par le filtre. La décision est faite après filtrage.

Le filtre médian ne protège pas aussi bien les premiers résultats suivant un mouvement zéros. Les résultats présentés incluent les résultats moins protégés. Il y a un compromis entre le temps de réaction et les erreurs lors de transition.

Dans les données présentées aux Figure 5-9 et Figure 5-10, le filtre médian utilisé a une grandeur de 5 fenêtres. Il est clair que l'utilisation du filtre permet de réduire substantiellement les taux d'erreurs. On voit d'après les Figure 5-9 et Figure 5-10 que plus le taux d'erreur initial est faible, plus le filtre est proportionnellement efficace (les mêmes données sont présentées de différentes façons pour plus de clarté). Dans le cas où le mouvement 2 est utilisé, les erreurs consécutives sont plus fréquentes, ce qui réduit l'efficacité du filtre médian. Cet effet est toutefois mineur dans les résultats présentés.

Il sera évidemment possible de remplacer les filtres médians par des méthodes plus poussées telles les chaînes de Markov cachées [BAH74]. De telles méthodes pourraient exploiter la connaissance des matrices de confusion pour réduire le taux d'erreur, particulièrement suivant les méthodes de classification donnant des valeurs probabilistes. Il est cependant peu probable que cette approche règle les problèmes de mouvement trop similaires tels les mouvements 2 et 8 de la situation présente.

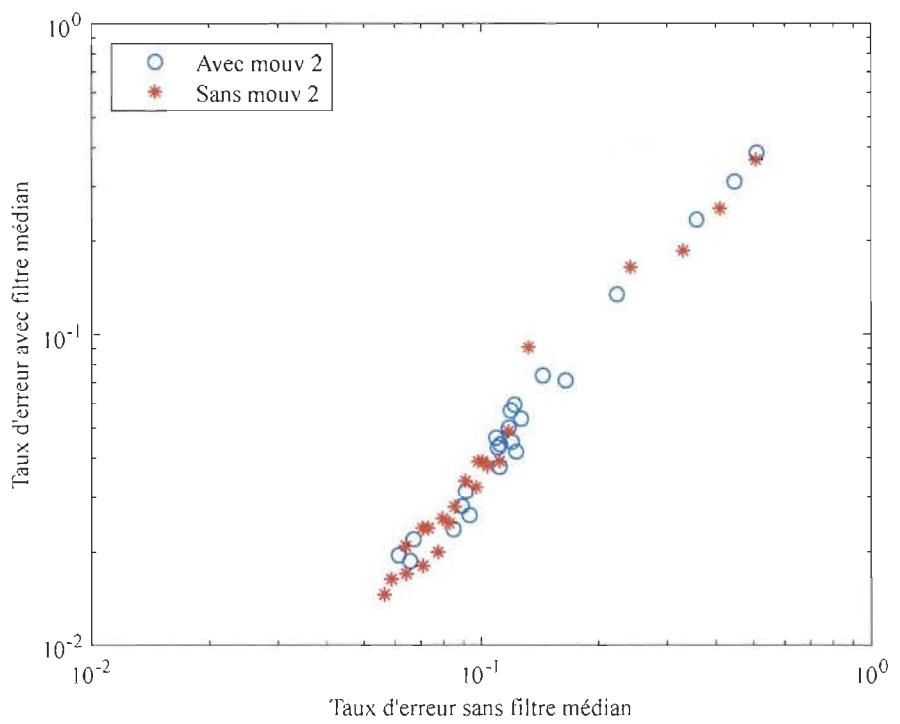


Figure 5-9 Performances du filtre médian

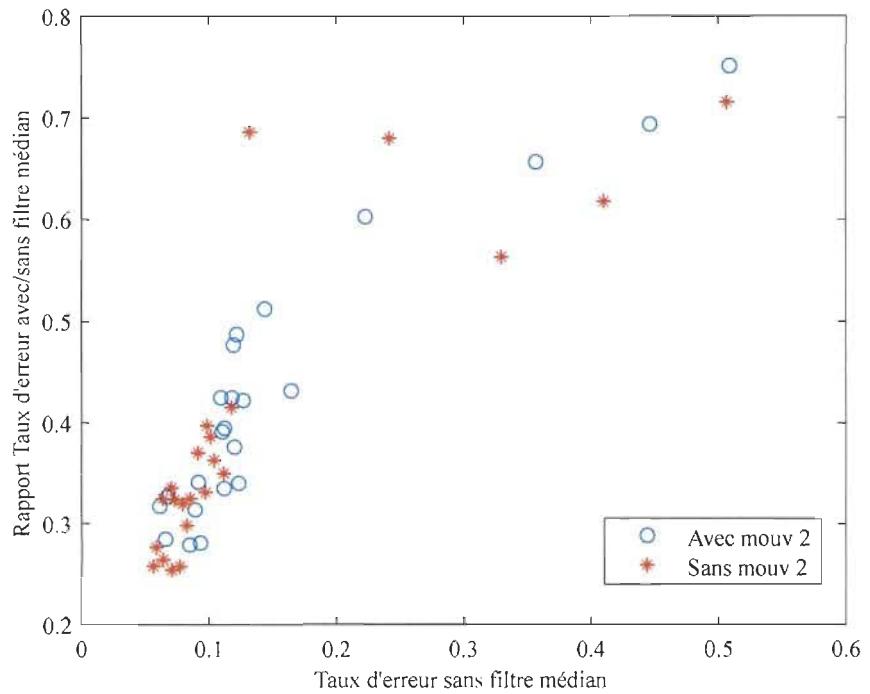


Figure 5-10 Représentation proportionnelle des performances du filtre médian

5.4.8 Temps de réponse

Les informations nécessaires pour calculer le temps de réponse de la méthode sont les suivantes :

- Fréquence d'échantillonnage : 2048Hz
- Taille des fenêtres : 256 échantillons (sans recouvrement)
- Période transitoire : 5 fenêtres
- Possible filtre médian de 5 fenêtres

On omet le temps de calcul et les délais induits par la communication entre les différents modules (capteurs à ordinateur à robot). La durée totale des données utilisées de 5 fenêtres est de 0.6250 secondes. Si on désire assurer les performances optimales données par le filtre médian, on doit doubler ce délai, pour un total de 1.25 secondes. De plus, le passage vers un mouvement 0 implique un retrait non causal de fenêtre. On doit donc allonger encore 5 fenêtres de délais pour un total de 1.875 secondes. Ce délai peut être comparé à celui proposé dans [GEN16], un article proposant une méthode dite instantanée, mais dont les performances s'améliorent de manière importante selon la taille d'une fenêtre, et donc d'un délai. Bien qu'il ne soit pas aisément de comparer des algorithmes différents évalués par une validation différente sur des données différentes, on trouve pour des performances inférieures avec un délai d'une seconde dans [GEN16]. On est donc dans le même ordre de grandeur. Il faut noter que peu d'effort a été fait pour réduire le délai total. Il y a probablement beaucoup de place à amélioration avant de voir une dégradation notable sur les taux d'erreur.

5.4.9 Problème d'invariance de la variance (et d'autres caractéristiques)

Bien que la variance du signal soit une caractéristique classique (si on peut dire ainsi pour une problématique récente!), elle possède un problème connu par rapport à l'invariance à la force. Autrement dit, un même mouvement fait avec plus de force modifie grandement la

caractéristique. Notons que le même argument est valable pour d'autres caractéristiques similaires telle la déviation standard, la puissance (moyenne des carrés), valeur absolue moyenne, etc... C'est pourquoi il pourrait sembler être préférable d'éviter cette caractéristique. La MDF semble à priori plus robuste par rapport à la variabilité selon la force. Cependant, cela n'a pas été démontré dans la littérature. Au contraire, il existe une relation entre la MDF et la puissance du signal [GER91]. On ne peut donc pas affirmer une robustesse supérieure des caractéristiques fréquentielles par rapport à la variance. De plus, la pente de la MDF étant un bon indicateur de l'état de fatigue musculaire [GON2012], elle n'est donc pas invariante face à celle-ci. Pour la FD, il a été démontré qu'elle est insensible à la fatigue, mais dépendante de la force appliquée [MES09]. Autre paramètre important est l'état de l'interface peau-électrode qui peut affecter grandement toutes les caractéristiques [HOG05] (bien que cela ne se trouve pas dans la littérature, on peut imaginer un impact sur la FD).

Il serait désirable qu'un système de reconnaissance de mouvement qui soit invariant en force, état de fatigue, positionnement et état de l'interface peau-électrodes de la matrice. Il est donc probable qu'un ensemble de caractéristiques soient nécessaires pour atteindre cet objectif. D'ailleurs, [MES09] propose un système à deux caractéristiques pour l'estimation de l'état de fatigue.

Bien que la SA n'ait pas montré d'aptitudes particulièrement impressionnantes pour la classification des mouvements, il reste une bonne possibilité que celle-ci amène une nouvelle forme de robustesse face à certains aspects dont l'invariance est souhaitable. La SA en relation avec la force, la fatigue, le positionnement et l'interface peau-électrode n'ont pas encore été étudiés et mériteraient de l'être. Il y aura probablement un compromis à faire entre l'invariance,

bénéficiant d'un grand nombre de caractéristiques, et la rapidité d'adaptation et d'entraînement du système, préférant un nombre réduit de caractéristiques.

Notons finalement que l'utilisation de multiples caractéristiques pourrait avoir des applications avantageuses pour la problématique de régression pour associer un niveau de contraction au mouvement [SCH13][HAH14][SMI16][NOU20].

5.4.10 Séparation des données

Il est habituel pour l'entraînement et l'évaluation des performances des réseaux neuronaux de répartir les données en trois groupes : entraînement, validation et test. Le groupe d'entraînement sert à produire l'adaptation des poids synaptiques du réseau. Le groupe de validation sert à sélectionner la structure du réseau et à choisir les paramètres des algorithmes d'entraînement de telle sorte à minimiser le sur-apprentissage. Le groupe de test quant à lui doit être gardé de côté pour évaluer les performances une fois que toutes les décisions ont été prises.

Il existe plusieurs méthodes pour séparer les données dans ces groupes. Les deux principaux sont la séparation aléatoire et la séparation en bloc. La séparation aléatoire nécessite une indépendance des différents échantillons selon l'ordre. Dans le contexte présent, c'est une indépendance temporelle qui est requise. La séparation en bloc est moins sensible à la dépendance selon l'ordre (temps). C'est celle-là qui est donc préférée. On remarque que des méthodes de validation croisée de type exclusion de données (« *k-fold* » et « *leave-one-out* ») utilisé pour simuler un groupe test comme utilisé dans [AMM15][GEN16] ont le même problème par rapport à la dépendance temporelle. En Annexe 4:, l'utilisation de la séparation aléatoire détaillée et il est montré que celle-ci vient induire en erreur en donnant des performances anormalement élevées.

Dans les travaux présentés, les données sont séparées selon les proportions suivantes :

- Groupe entraînement = 21/51
- Groupe validation = 9/51
- Groupe test = 20/51.

5.5 RÉSULTATS

Les résultats sont présentés dans cette section. Premièrement, on donne une idée des performances et des différences de performances requises pour atteindre des seuils de signification statistique. Ensuite, on présente les principaux résultats obtenus, puis on montre comment les résultats auraient pu être améliorés.

5.5.1 Inférence statistique pour les performances obtenues

Il y a deux vérifications statistiques qui doivent être faites pour appuyer l'analyse des résultats obtenus. D'un côté, il faut vérifier que le taux d'erreur soit statistiquement significatif. Il est primordial d'éliminer la possibilité que des signaux aléatoires, sans information utile, aient pu produire les taux d'erreurs obtenus. De l'autre côté, la comparaison de performances entre divers algorithmes s'intéresse à la différence entre les taux d'erreur. Cette différence peut être due au hasard. Il est donc nécessaire de vérifier l'effet du hasard sur celle-ci.

La problématique principale pour effectuer les calculs est de savoir combien de données sont utilisées. Dans toutes formules de proportion, il y a un N qui intervient. Or, les données comptées doivent être indépendantes et il n'est absolument pas acquis que des fenêtres consécutives pour un même mouvement répondent à ce prérequis. En s'intéressant principalement au groupe test, le nombre de données peut prendre 4 valeurs extrêmes :

- 1) Tous les mouvements sont utilisés, les fenêtres sont considérées indépendantes : $N = 18000$,
- 2) Tous les mouvements sont utilisés, les fenêtres sont considérées dépendantes : $N = 450$,
- 3) Le mouvement 2 est retiré, les fenêtres sont considérées indépendantes : $N = 16800$,
- 4) Le mouvement 2 est retiré, les fenêtres sont considérées dépendantes : $N = 420$.

Il doit exister un nombre de données effectif situé entre les extrêmes et qui est fonction de la dépendance réelle entre les données. Aussi, le retrait du mouvement deux réduit le nombre de données disponibles. L'impact du retrait du mouvement est par contre aisément traitable.

L'hypothèse nulle sur le taux d'erreur est simplement obtenue par l'inverse du nombre de mouvement considérés. On aura donc une hypothèse nulle de 0.9333 (ou taux de succès de 0.0667) lorsque tous les mouvements sont gardés et de 0.9286 (ou taux de succès de 0.0714) lorsque le mouvement 2 est retiré. Le seuil de rejet de l'hypothèse nulle varie selon le nombre de fenêtres considérées indépendantes et le nombre de mouvement. Toutefois, un minorant du taux d'erreur se montre largement suffisant pour conclure sur la validité des résultats. En utilisant seulement 420 fenêtres de test et avec le mouvement 2 retiré, on obtient déjà à 87.83% d'erreur un résultat à 4 écart-types, soit ayant une valeur p de 3.16E-05. Il va donc dire que même les pires performances présentées ne sont clairement pas seulement obtenues par hasard. Le fait que plusieurs essais sont faits ne change en rien cette conclusion, surtout pour le résultat du groupe test du réseau de neurone sélectionné à partir de la validation. Il n'est donc pas nécessaire d'appliquer de corrections de type Bonferroni. Mais même en utilisant la correction, on a pour un seuil de signification de 5% simplement besoin de dépasser les 11% de succès (89% d'erreur) en utilisant le cas le plus conservateur ($N = 420$).

Tableau 5-1 Déviation standard du taux de succès selon l'hypothèse nulle

H0 \ N =	18000	450	16800	420
0,0667	0,0019	0,0118	0,0019	0,0122
0,0714	0,0019	0,0121	0,0020	0,0126

L'hypothèse nulle pour la différence entre les taux d'erreurs est évidemment que celle-ci est nulle. Le calcul des tests d'hypothèse sur cette différence devrait être fait pour toutes les paires de taux d'erreur. Aussi, le calcul sera seulement approximatif étant donné la dépendance entre les données précédemment discutée. Or, une idée de l'ordre de grandeur sera suffisante pour vérifier les conclusions tirées. Le Tableau 3-2 montre des exemples de différences et de valeurs p selon le nombre de données considérés. Les calculs sont faits à partir de [ALT00]. De ce tableau, on retient que pour la même différence, la valeur p est plus forte lorsque les taux d'erreurs sont près de 0. Aussi, en restant conservateur, une différence de 0.02 sur le taux d'erreur peut être considérée significative lorsque les taux d'erreurs sont faibles. Il faut encore une fois garder à l'esprit que plusieurs expériences sont faites et qu'il risque donc naturellement d'y avoir des disparités de performances dues au simple hasard. Cette fois-ci, même si les comparaisons sont faites dans le cadre des performances sur un groupe de test, au moins une des proportions n'est pas sélectionnée à priori.

Tableau 5-2 Exemples de valeurs-p de différentes différences de proportions

% ERR 1	% ERR 2	Avec Mouv. 2		Sans Mouv. 2	
		N = 30x40x15	N = 30x15	N = 30x40x14	N = 30x14
10	9	0,0012	0,6092	0,0020	0,6214
10	6	<0,0001	0,0271	<0,0001	0,0327
2	1	<0,0001	0,2174	<0,0001	0,2335
2	0	<0,0001	0,0026	<0,0001	0,0036
1	0	<0,0001	0,0335	<0,0001	0,0400

5.5.2 Résultats principaux

Les Tableau 5-3 et Tableau 5-4 présentent les résultats avec et sans le mouvement 2 sous forme de taux d'erreur. Les résultats de validation sont présentés les 30 essais avec les performances médianes, pires (Max) et meilleures (Min). Les meilleures performances sont aussi présentées avec le filtre médian. Les résultats sur le groupe test sont présentés pour le meilleur réseau de neurone entraîné lors de la validation pour chaque groupe de caractéristiques. En caractères gras sont montrés les résultats du réseau de neurones sélectionné lors de la validation parmi tous les groupes de caractéristiques. Ces résultats sont sans biais du aux tests multiples.

Tableau 5-3 Performance avec mouvement 2

VAR	MDF	FD Higuchi		Z Higuchi		Median	Max	Min	Median Filter	Test	Test + Median Filter
		FD	Katz	Z	Katz						
1	0	0	0	0	0	0.0710	0.1400	0.0580	0.0194	0.1174	0.0498
0	1	0	0	0	0	0.0557	0.1154	0.0509	0.0204	0.0844	0.0235
0	0	1	0	0	0	0.0654	0.0794	0.0480	0.0180	0.0912	0.0311
0	0	0	1	0	0	0.1170	0.1570	0.1004	0.0578	0.2228	0.1341
0	0	0	0	1	0	0.3744	0.3798	0.3637	0.2078	0.4460	0.3087
0	0	0	0	0	1	0.3715	0.4144	0.3543	0.2489	0.5087	0.3816
1	1	0	0	0	0	0.0550	0.1200	0.0415	0.0124	0.0887	0.0278
0	1	1	0	0	0	0.0409	0.0580	0.0343	0.0150	0.0612	0.0194
0	1	0	1	0	0	0.0658	0.0820	0.0544	0.0409	0.1432	0.0732
0	1	0	0	1	0	0.0542	0.1070	0.0498	0.0207	0.0928	0.0260
0	1	0	0	0	1	0.0774	0.1507	0.0704	0.0344	0.1262	0.0532
0	0	1	1	0	0	0.0720	0.1333	0.0600	0.0319	0.1213	0.0590
0	0	0	0	1	1	0.2307	0.2428	0.2152	0.1469	0.3565	0.2335
0	1	1	1	0	0	0.0601	0.1178	0.0456	0.0283	0.1100	0.0430
0	1	0	0	1	1	0.0643	0.0720	0.0572	0.0257	0.1113	0.0373
0	1	0	0	1	1	0.0633	0.1365	0.0561	0.0311	0.1226	0.0417
0	1	1	0	1	0	0.0440	0.1056	0.0315	0.0143	0.0655	0.0186
0	1	0	1	0	1	0.0718	0.1320	0.0543	0.0337	0.1638	0.0706
1	1	1	1	0	0	0.0531	0.1093	0.0361	0.0280	0.1116	0.0440
1	1	1	0	1	0	0.0406	0.1074	0.0352	0.0161	0.0668	0.0218
1	1	0	1	0	1	0.0612	0.1383	0.0439	0.0270	0.1195	0.0449
0	1	1	1	1	1	0.0569	0.0763	0.0480	0.0291	0.1089	0.0462
1	1	1	1	1	1	0.0508	0.1265	0.0359	0.0363	0.1187	0.0565

Tableau 5-4 Performance sans mouvement 2

VAR	MDF	FD Higuchi		FD Katz		Median	Max	Min	Median Filter	Test	Median Filter
		Z	Higuchi	Z	Katz						
1	0	0	0	0	0	0.0593	0.1321	0.0446	0.0139	0.0982	0.0389
0	1	0	0	0	0	0.0421	0.1139	0.0341	0.0073	0.0772	0.0198
0	0	1	0	0	0	0.0481	0.0585	0.0385	0.0143	0.0912	0.0337
0	0	0	1	0	0	0.0825	0.1472	0.0617	0.1073	0.2420	0.1641
0	0	0	0	1	0	0.3389	0.3800	0.3325	0.1669	0.4099	0.2528
0	0	0	0	0	1	0.3524	0.3935	0.3216	0.2310	0.5068	0.3622
1	1	0	0	0	0	0.0367	0.1073	0.0325	0.0058	0.0825	0.0245
0	1	1	0	0	0	0.0273	0.0875	0.0212	0.0038	0.0705	0.0236
0	1	0	1	0	0	0.0282	0.0980	0.0228	0.0054	0.0730	0.0236
0	1	0	0	1	0	0.0429	0.1702	0.0375	0.0083	0.0852	0.0276
0	1	0	0	0	1	0.0568	0.0625	0.0514	0.0190	0.1174	0.0486
0	0	1	1	0	0	0.0380	0.1054	0.0260	0.0113	0.1038	0.0376
0	0	0	0	1	1	0.1962	0.2575	0.1887	0.0962	0.3298	0.1855
0	1	1	1	0	0	0.0244	0.0964	0.0169	0.0042	0.0565	0.0145
0	1	0	0	1	1	0.0456	0.1127	0.0409	0.0117	0.1114	0.0389
0	1	0	0	1	1	0.0466	0.1113	0.0421	0.0135	0.0971	0.0321
0	1	1	0	1	0	0.0276	0.0341	0.0236	0.0036	0.0639	0.0207
0	1	0	1	0	1	0.0325	0.1010	0.0238	0.0083	0.1010	0.0389
1	1	1	1	0	0	0.0209	0.0887	0.0173	0.0042	0.0642	0.0169
1	1	1	0	1	0	0.0257	0.0942	0.0208	0.0750	0.1320	0.0904
1	1	0	1	0	1	0.0275	0.0986	0.0187	0.0058	0.0794	0.0253
0	1	1	1	1	1	0.0251	0.0952	0.0179	0.0038	0.0708	0.0179
1	1	1	1	1	1	0.0212	0.0256	0.0179	0.0038	0.0588	0.0162

Les performances des méthodes SA sont décevantes face aux autres méthodes, mais sont statistiquement significatives. Leur addition aux autres méthodes n'est pas impressionnante non-plus, venant souvent empirer les performances. Les taux d'erreurs obtenus de 6.6% et de 5.7% avec et sans le mouvement 2 sont raisonnables face à ce qui a été trouvé dans la littérature. Toutefois, ils sont obtenus de manière causale contrairement à plusieurs résultats dans la littérature. Aussi, ils ne sont pas le résultat d'essais multiples, ce qui augmente leur validité. L'impact du filtre médian est aussi sans biais, mais l'impact du filtre médian pourrait être étudié séparément. On cherchera à voir si de meilleurs résultats sont possibles mais il est trop tard pour avoir des résultats sans biais. Il sera possible cependant d'observer que de meilleurs résultats sont accessibles.

5.5.3 Augmentation du taux d'erreur selon le temps

Il se passe un certain temps entre les différentes expériences, l'ensemble des données ayant été prises sur une période de 3 heures. Or, plusieurs conditions d'expérimentations peuvent changer entre le début et la fin de la prise de mesures, tant au niveau de la connexion entre la matrice de capteur et la peau que dans l'état même des muscles (ex.: fatigue musculaire). On a donc à faire à des signaux non stationnaires. On peut s'attendre à voir une dégradation de l'erreur plus le point de validation ou de test est éloigné. Pour illustrer ce phénomène, deux graphiques sont montrés. En premier, la Figure 5-11 montre l'erreur cumulative en fonction du temps, en unité de fenêtre traitée sans mouvement 2 (omettant les mouvements zéros, les transitions le temps entre les expériences). Si le taux d'erreur était constant, on s'attendrait à une droite. On voit que l'erreur cumulative a plutôt une forme légèrement parabolique.

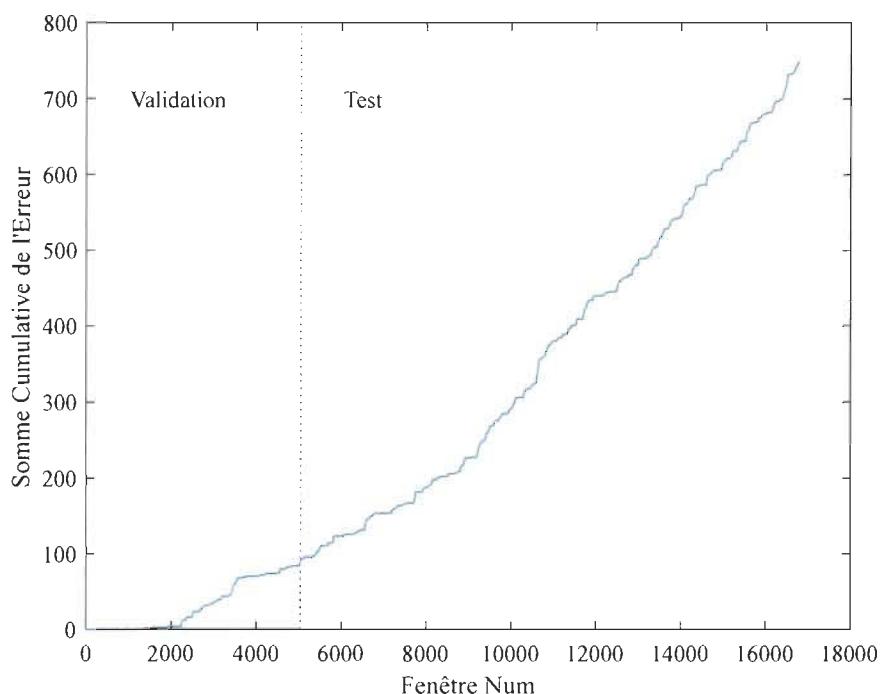


Figure 5-11 Erreur cumulative selon le temps (en termes de fenêtre de données)

En deuxième, la Figure 5-12 présente le taux d'erreur selon l'expérience pour le groupe test. Un graphique similaire a été fait pour le groupe de validation. Il faut dire que le moment précis des expériences n'a pas été contrôlé rigoureusement. De prochaines mesures devraient prendre en note la date et l'heure. Néanmoins, on constate une tendance positive du taux d'erreur plus le temps avance.

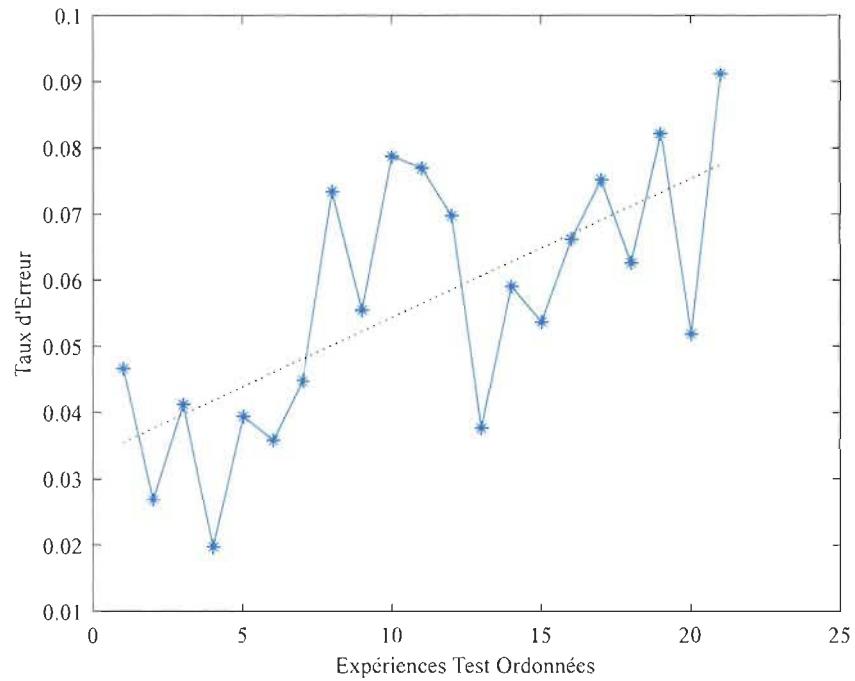


Figure 5-12 Taux d'erreur selon l'expérience, groupe de test

Pour valider que cette tendance est significative, plusieurs approches ont été utilisées :

- Une valeur p de la pente de la droite de régression est obtenue par test de permutation,
- Un intervalle de confiance de la pente de la droite de régression est établi avec l'aide du « *bootstrap* » des résidus,
- Un calcul robuste de la pente selon la méthode de Theiler-Sen [SEN68] est fait,
- Une valeur p de la pente de Theiler-Sen est obtenue par permutation.

Ces calculs ont été faits pour toutes les combinaisons d'entrées, avec et sans mouvement 2, pour le groupe de validation et le groupe de test. Les résultats sont montrés aux Tableau 5-5 et Tableau 5-6.

Tableau 5-5 Pentes du taux d'erreur pour du groupe de validation

VAR	MDF	FD Higuchi	FD Katz	Z Higuchi	Z Katz	Pente Taux		Pente Rang		Pente Taux	
						d'Erreur	p-Value	2.5%	97.5%	d'Erreur	p-Value
						Régression	Permutation	Bootstrap	Bootstrap	Theiler-Sen	Permutation
1	0	0	0	0	0	0.0071	0.0317	0.0018	0.0126	0.0070	0.0633
0	1	0	0	0	0	0.0043	0.0831	-0.0005	0.0091	0.0051	0.0537
0	0	1	0	0	0	0.0063	0.0711	-0.0004	0.0128	0.0054	0.1294
0	0	0	1	0	0	0.0125	0.0538	0.0010	0.0238	0.0107	0.0824
0	0	0	0	1	0	0.0091	0.0777	-0.0009	0.0191	0.0086	0.1020
0	0	0	0	0	1	0.0132	0.1201	-0.0049	0.0311	0.0180	0.0823
1	1	0	0	0	0	0.0053	0.0843	-0.0006	0.0113	0.0056	0.0859
0	1	1	0	0	0	0.0036	0.0712	-0.0002	0.0074	0.0029	0.1569
0	1	0	1	0	0	0.0045	0.0539	0.0004	0.0085	0.0035	0.1287
0	1	0	0	1	0	0.0044	0.1712	-0.0032	0.0121	0.0026	0.1832
0	1	0	0	0	1	0.0089	0.0542	0.0007	0.0172	0.0054	0.1171
0	0	1	1	0	0	0.0064	0.0452	0.0008	0.0120	0.0054	0.1061
0	0	0	0	1	1	0.0157	0.0696	-0.0006	0.0321	0.0112	0.1660
0	1	1	1	0	0	0.0033	0.1045	-0.0008	0.0074	0.0025	0.1110
0	1	0	0	1	1	0.0059	0.1159	-0.0020	0.0138	0.0040	0.2054
0	1	0	0	1	1	0.0049	0.1660	-0.0034	0.0131	0.0041	0.1671
0	1	1	0	1	0	0.0046	0.0564	0.0002	0.0090	0.0033	0.1348
0	1	0	1	0	1	0.0063	0.0757	-0.0004	0.0130	0.0054	0.0756
1	1	1	1	0	0	0.0040	0.0727	-0.0003	0.0082	0.0036	0.0985
1	1	1	0	1	0	0.0033	0.0982	-0.0008	0.0073	0.0034	0.1044
1	1	0	1	0	1	0.0051	0.0479	0.0006	0.0095	0.0048	0.0796
0	1	1	1	1	1	0.0043	0.0866	-0.0006	0.0092	0.0036	0.1146
1	1	1	1	1	1	0.0027	0.1747	-0.0020	0.0074	0.0019	0.2077

Tableau 5-6 Pentes du taux d'erreur pour du groupe de test

VAR	MDF	FD Higuchi		Z Katz		Pente Taux d'Erreur Régression		Pente Rang Permutation		Pente Rang Bootstrap		Pente Taux d'Erreur Theiler-Sen	
		FD	Higuchi	Z	Katz	p-Value	2,5%	Bootstrap	97,5%	Bootstrap	p-Value	Permutation	
1	0	0	0	0	0	0.0028	0.0129	0.0006	0.0050	0.0025	0.0106		
0	1	0	0	0	0	0.0018	0.0097	0.0005	0.0031	0.0018	0.0119		
0	0	1	0	0	0	0.0018	0.0220	0.0003	0.0034	0.0018	0.0420		
0	0	0	1	0	0	0.0017	0.1360	-0.0011	0.0046	0.0016	0.1106		
0	0	0	0	1	0	0.0026	0.0059	0.0008	0.0043	0.0021	0.0122		
0	0	0	0	0	1	0.0016	0.1379	-0.0011	0.0043	0.0018	0.1441		
1	1	0	0	0	0	0.0017	0.0154	0.0004	0.0030	0.0018	0.0159		
0	1	1	0	0	0	0.0018	0.0050	0.0007	0.0030	0.0018	0.0094		
0	1	0	1	0	0	0.0020	0.0036	0.0008	0.0031	0.0020	0.0069		
0	1	0	0	1	0	0.0012	0.0306	0.0001	0.0024	0.0013	0.0415		
0	1	0	0	0	1	0.0024	0.0051	0.0008	0.0040	0.0025	0.0079		
0	0	1	1	0	0	0.0031	0.0014	0.0015	0.0048	0.0030	0.0024		
0	0	0	0	1	1	0.0029	0.0290	0.0002	0.0056	0.0025	0.0617		
0	1	1	1	0	0	0.0021	0.0006	0.0011	0.0031	0.0022	0.0006		
0	1	0	0	1	1	0.0021	0.0223	0.0003	0.0038	0.0021	0.0318		
0	1	0	0	1	1	0.0017	0.0277	0.0001	0.0032	0.0016	0.0475		
0	1	1	0	1	0	0.0013	0.0157	0.0003	0.0023	0.0013	0.0151		
0	1	0	1	0	1	0.0022	0.0147	0.0005	0.0040	0.0023	0.0257		
1	1	1	1	0	0	0.0019	0.0056	0.0007	0.0032	0.0021	0.0053		
1	1	1	0	1	0	0.0009	0.0878	-0.0003	0.0021	0.0010	0.0911		
1	1	0	1	0	1	0.0020	0.0017	0.0009	0.0031	0.0021	0.0031		
0	1	1	1	1	1	0.0023	0.0029	0.0009	0.0036	0.0023	0.0024		
1	1	1	1	1	1	0.0019	0.0052	0.0007	0.0031	0.0018	0.0108		

On remarque principalement que les résultats sont généralement montrés nettement plus significatifs pour le groupe test que le groupe validation. Cela est principalement dû au nombre de point de validation (9) et de test (20). Utiliser les points des deux séries serait biaisé du fait qu'une optimisation supplémentaire est faite par rapport au groupe validation. Les pentes vont aussi généralement dans la direction positive, peu importe l'ensemble d'entrée, autant pour le groupe validation que test. La démonstration de la dégradation des performances suggère fortement l'utilisation d'une adaptation. Étant donné cette réduction des performances selon le temps, on peut aussi supposer que si le groupe test était temporellement juste à côté du groupe d'entraînement, les performances seraient meilleures. Cette dernière remarque est exploitée à la section suivante.

5.5.4 Inversion des groupes d'entraînement et validation

Le constat de la dérive du taux d'erreur selon le temps amène l'idée d'inverser l'ordre des groupes d'entraînement et validation. De cette manière, le groupe test se rapproche temporellement du groupe d'entraînement. Quant au groupe de validation, il devient utilisable selon l'idée suivante : on espère qu'une bonne capacité de prédiction anti-causale (vers la gauche sur l'échelle du temps) permettra une bonne prédiction causale (vers la droite sur l'échelle du temps).

Les résultats du Tableau 5-7 ont été obtenus par l'inversion de l'ordre des groupes. Par contre, moins d'efforts de simulation a été réduit. Seulement 3 initialisations sont faites pour chaque réseau de neurones et seules les valeurs médianes des résultats sont montrées. Aussi, on n'a pas appliqué le filtre médian sur les sorties. Étant donné qu'ils ont été faits à posteriori, les résultats présentés n'ont pas le même niveau de confiance que ceux obtenus aux Tableau 5-3 et Tableau 5-4.

Tableau 5-7 Performances avec inversion de l'ordre des groupes entraînement et validation

VAR	MDF	Avec Mouvement 2		Avec Mouvement 2		Avec Mouvement 2		Sans Mouvement 2	Sans Mouvement 2	Sans Mouvement 2
		Entrainement	Validation	Test	Entrainement	Validation	Test	Entrainement	Validation	Test
1	0	0.0562	0.0772	0.1356	0.0435	0.0631	0.1067			
0	1	0.0131	0.0152	0.0669	0.0115	0.0143	0.0589			
0	0	0.0060	0.0144	0.0551	0.0082	0.0143	0.0562			
0	0	0.0084	0.0030	0.0919	0.0028	0.0032	0.0696			
0	0	0.2610	0.2683	0.4013	0.2178	0.2500	0.3765			
0	0	0.2110	0.2050	0.4179	0.2381	0.2206	0.4245			
1	1	0.0057	0.0094	0.0506	0.0078	0.0109	0.0528			
0	1	0.0023	0.0074	0.0462	0.0017	0.0065	0.0376			
0	1	0.0025	0.0041	0.0429	0.0030	0.0032	0.0343			
0	1	0.0075	0.0124	0.0675	0.0077	0.0117	0.0561			
0	1	0.0019	0.0100	0.0616	0.0051	0.0099	0.0571			
0	0	0.0017	0.0402	0	0.0020	0.0020	0.0290			
0	0	0.0936	0.1011	0.2632	0.0795	0.0806	0.2402			
0	1	0.0020	0.0317	0.0003	0.0024	0.0024	0.0287			
0	1	0.0009	0.0096	0.0597	0.0043	0.0093	0.0532			
0	1	0.0057	0.0107	0.0698	0.0032	0.0099	0.0560			
0	1	0.0048	0.0424	0.0020	0.0054	0.0054	0.0355			
0	1	0.0033	0.0041	0.0495	0.0014	0.0026	0.0304			
1	1	0.0022	0.0348	0	0.0020	0.0020	0.0223			
1	1	0.0014	0.0044	0.0413	0	0.0044	0.0327			
1	1	0.0006	0.0020	0.0341	0	0.0026	0.0245			
0	1	0.0006	0.0028	0.0386	0.0003	0.0024	0.0266			
1	1	0.0004	0.0031	0.0356	0	0.0024	0.0216			

Encore une fois, les résultats sans le mouvement 2 sont supérieurs. Le Tableau 5-8 compare les performances sur le groupe test sans le mouvement 2, pour les deux ordres de séparations des données. Pour la plupart des réseaux neuronaux, il y a un gain intéressant qui est fait par l'inversion de l'ordre des groupes. Notamment, pour le réseau utilisant la MDF et les deux méthodes de FD, la réduction du taux d'erreur est de près de 50%. Il y a aussi probablement un gain de performance possible par l'optimisation de la répartition des données entre les groupes d'entraînement et validation.

Tableau 5-8 Comparaison des performances selon l'ordre des groupes Entrainement, Validation et Test

VAR	MDF	FD Higuchi	FDKatz	Z Higuchi	Z Katz	Entrainement		Validation		Différence Relative (A-B)/A	
						Validation	Test (A)	Entrainement	Test (B)		
-	0	0	0	0	0	0,0982	0,1067	-0,0085	-0,09		
0	1	0	0	0	0	0,0772	0,0589	0,0183	0,24		
0	0	1	0	0	0	0,0912	0,0562	0,0350	0,38		
0	0	0	1	0	0	0,2420	0,0696	0,1724	0,71		
0	0	0	0	1	0	0,4099	0,3765	0,0334	0,08		
0	0	0	0	0	1	0,5068	0,4245	0,0823	0,16		
1	1	0	0	0	0	0,0825	0,0528	0,0297	0,36		
0	1	1	0	0	0	0,0705	0,0376	0,0329	0,47		
0	1	0	1	0	0	0,0730	0,0343	0,0387	0,53		
0	1	0	0	1	0	0,0852	0,0561	0,0291	0,34		
0	1	0	0	0	1	0,1174	0,0571	0,0603	0,51		
0	0	1	1	0	0	0,1038	0,0290	0,0748	0,72		
0	0	0	0	1	1	0,3298	0,2402	0,0896	0,27		
0	1	1	1	0	0	0,0565	0,0287	0,0278	0,49		
0	1	0	0	1	1	0,1114	0,0532	0,0582	0,52		
0	1	0	0	1	1	0,0971	0,0560	0,0411	0,42		
0	1	1	0	1	0	0,0639	0,0355	0,0284	0,44		
0	1	0	1	0	1	0,1010	0,0304	0,0706	0,70		
1	1	1	1	0	0	0,0642	0,0223	0,0419	0,65		
1	1	1	0	1	0	0,1320	0,0327	0,0993	0,75		
1	1	0	1	0	1	0,0794	0,0245	0,0549	0,69		
0	1	1	1	1	1	0,0708	0,0266	0,0442	0,62		
1	1	1	1	1	1	0,0588	0,0216	0,0372	0,63		

5.6 DISCUSSION

Les performances qui peuvent être affirmés sont un taux d'erreur de 0.0655 avec tous les mouvements (15 mouvements) et de 0.0565 sans le mouvement 2 (14 mouvements). Aussi, en considérant le filtre médian, des taux d'erreur inférieurs à 2% peuvent être considérés. Ces résultats ont été obtenus avec un strict retrait du groupe test tout au long de l'entraînement et de la sélection des structures du réseau de neurones. Bien que ces résultats se comparent déjà bien à ce qui se trouve dans la littérature, des gains importants ont été ciblés. L'utilisation du simple filtre médian a le potentiel de réduction du taux d'erreur de 75%. Avec l'inversion des groupes d'entraînement et de validation et le filtrage médian, on tomberait sous la barre des 1% d'erreur.

de manière franche. De plus, selon la rapidité d'adaptation du système au changement, le taux d'erreur pourrait être abaissé substantiellement encore une fois.

Les FD sont montré être d'excellents compléments à la MDF. Si d'un côté les FD en elles-mêmes peuvent atteindre des performances respectables (surtout pour la méthode d'Higuchi), leur combinaison avec la MDF est particulièrement efficace. De plus, l'utilisation des deux méthodes FD ensemble donne de meilleurs résultats que pris individuellement. Cela va dans le sens de la complémentarité des deux méthodes. La MDF et les deux méthodes FD utilisées ensemble donnent les meilleurs résultats lorsque le mouvement 2 est retiré. Malheureusement, si seulement le nombre de mouvement (420) est considéré dans le calcul de la valeur p, celle-ci est de 0.23, ce qui est peu probant. Avec 16800 fenêtres considérées indépendantes, la valeur p tombe sous 0.0001. La réalité est quelque part entre les deux. On peut conclure que la FD est une bonne option pour prédire le mouvement et que l'union de la MDF et des méthodes FD est un candidat qui a un bon potentiel.

Les performances de la SA ont été décevantes. Cependant elles ont montré clairement contenir de l'information. L'union des scores de SA selon les deux méthodes semblent donner de meilleurs résultats, montrant la complémentarité de celles-ci.

Il peut y avoir un problème de précision des scores lié au nombre de données de substitution. Malgré les 200 séries générées, il se trouve encore environ 10% d'erreur sur les scores. Cela peut être problématique. Pour le problème de détection de mouvement en temps réel, il est de beaucoup préférable que la FD soit performante par rapport à la SA étant donné la complexité de calcul nécessaire associée à cette dernière.

Il est possible que l'information utile contenue dans les scores de la SA soit extraite par le réseau de neurones lorsque la MDF et la FD sont utilisés conjointement. Dans ce cas, ce serait effectivement l'information non-linéaire de la FD qui viendrait compléter la MDF. Il serait intéressant de vérifier si les scores de la SA peuvent être obtenus à partir de la MDF et de la FD. Il reste toutefois possible que la MDF et la FD soulignent simplement différents aspects du spectre de puissance.

Les scores de la SA calculés à partir de la FD selon Higuchi ne montrent que légèrement une non-linéarité. Parmi les fenêtres étant associées à un mouvement et hors transition, il y a 2.8% des scores qui dépassent la barrière de 3 écarts-types. Si distribuée normalement, on s'attendrait à 10 fois moins, mais cette prémissse n'a pas été démontrée. Toutefois, en considérant que le fenêtrage des données et des données de substitution rend la SA beaucoup plus conservatrice, il n'est pas exclu que les signaux aient une importante non-linéarité.

C'était un premier jet pour la SA et la détection de mouvements. Bien que ses performances n'aient pas été des plus impressionnantes, on peut s'attendre à des améliorations possibles tant par rapport aux choix des paramètres pour son calcul ainsi que par rapport à son utilisation pour compléter d'autres méthodes. De plus, la SA pourrait se baser sur d'autres caractéristiques non-linéaires que la FD.

Chapitre 6: CONCLUSION

La thèse couvre plusieurs axes, passant de l'utilisation des matrices de capteurs à l'analyse non-linéaire. L'importance de la thèse se trouve non seulement dans les résultats obtenus mais encore plus dans son grand champ d'applications. Cette conclusion souligne premièrement les contributions de la thèse, liste des questions restantes et montre différents domaines de recherches ouverts.

6.1 CONTRIBUTION À L'ÉTUDE DES SYSTÈMES SEMG

Globalement, il a été montré que le matrices sEMG contiennent de l'information utile concernant le LBP. On peut conclure qu'une meilleure compréhension du LBP est possible grâce aux matrices.

Il a été montré que l'utilisation de la matrice EMG a permis d'exploiter la MDF pour obtenir de l'information utile. Alors qu'avant seul une différence significative entre un groupe LBP et contrôle avait été déterminé pour un seul capteur, un taux de succès de 70% a été atteint à l'aide des matrices. La possibilité d'obtenir une grande quantité d'information a permis aussi de valoriser l'information non-linéaire pour pouvoir faire une classification avec des taux de succès dépassant les 90% pour la détection du LBP. On a montré l'utilité de la sélection de valeurs non-linéaires extrêmes, celles-ci étant les plus « intéressantes ». Aussi, une méthode de retrait du PLI qui exploite la matrice de capteur a été développée.

Notons que même si les taux de succès avaient avoisiné les 100%, il serait encore pertinent de trouver d'autres caractéristiques du signal pour mieux comprendre le LBP. Idéalement, il aurait été souhaitable de pouvoir faire des sous-classes de sujets LBP, peut-être par méthodes de

« clustering ». Pour ce faire, il est idéal d'avoir des sous-groupes fortement séparés, ce qui est loin d'être le cas avec les caractéristiques existantes.

6.2 CONTRIBUTIONS À L'UTILISATION DE LA SA

Le point central de la thèse a été de montrer que la SA peut servir à autre chose que de simplement affirmer qu'un signal est non-linéaire ou des variations mineures autour de ce thème. Mais pour ce faire, on a adapté la SA pour donner un résultat continu. Cette version de la SA se différentie d'une variable appelée signification ou « *significance* » [THE92] simplement par le retrait d'une valeur absolue, mais permet d'obtenir un score variant de manière monotone par rapport à une certaine forme de non-linéarité. Aussi, un calcul de la précision de cette version de la SA selon le nombre de séries de substitution a dû être fait. Il a été possible grâce à la SA de créer un score qui est relativement indépendant du spectre de puissance. Ce score a été montré utile comme caractéristique de signaux sEMG pour la détection de sujets LBP.

La complémentarité de l'information non-linéaire des méthodes fractales de Katz et Higuchi a pu être explicitée par l'utilisation de la SA. Celle-ci a été démontrée sur des séries non-linéaires classiques. La variable de signification de [THE92] n'aurait pas pu séparer les différentes séries non-linéaires étudiées. Puis, les scores de la SA de deux méthodes fractales ont été utilisés de manière complémentaire pour permettre un niveau de classification supérieur de sujets LBP.

La SA s'est montrée apte à extraire une information utile dans le contexte de détection de mouvements basé sur les matrices sEMG. Bien que les performances n'aient pas été des plus remarquables, elles montraient clairement la présence d'information discriminante. L'utilisation conjointe de la MDF et des FDs a été montrée très efficace. Mais il est possible qu'avec un

raffinement des paramètres utilisés il soit possible d'améliorer davantage ces résultats grâce à la SA.

6.3 CONTRIBUTIONS À L'INTERPRÉTATION DE LA SA

L'interprétation de la SA est généralement difficile [PRI95]. La SA étant interprétée, le plus souvent à tort, selon la caractéristique non-linéaire qui lui est associée on a montré des contre-exemples à cette approche. Entre autres, la synchronisation de signaux de potentiels d'action n'avait rien d'autosimilaires, mais la FD a donné des résultats convaincants. La thèse suggère donc de ne pas limiter l'interprétation de la SA à la caractéristique, mais plutôt de chercher possiblement des causes physiques ou physiologiques.

Aussi, l'étude de la vitesse de conduction et de la synchronisation a aussi montré la possibilité d'effets croisés sur la SA entre différents paramètres de systèmes. De plus, une interprétation d'un point de vue du spectre de la phase dans le domaine de Fourier montre que pour la même série, la SA peut être interprétée de plusieurs angles. Pour un même signal, on peut parler de manière similaire de synchronisation et de phase non-aléatoire.

Si les interprétations discutées sont des avenues intéressantes menant à de l'information sur des réalités physiques, d'autres interprétations sont en fait des artefacts causés par la méthode en elle-même. L'effet du fenêtrage en est un exemple. La compréhension de celui-ci a été améliorée.

Bien que quelques interprétations aient été développées dans la thèse, la compréhension des résultats de la SA reste loin d'être complète. Notons aussi que les interprétations pourront mener vers de nouvelles applications. Comme discuté plus loin.

6.4 QUESTIONS RESTANTES

Un beau problème qui arrive avec de nouvelles avenues est qu'un grand nombre de questions émergent. Une liste restreinte des questions restantes qui aurait été d'un intérêt pour la thèse est dressée ici.

6.4.1 Lien avec les autres travaux faits au laboratoire GRAN

Pour faire un lien avec les autres travaux faits au laboratoire GRAN dans le contexte de l'utilisation des matrices de capteurs sEMG, un bon test serait d'utiliser la variabilité motrice, caractéristique étudiée dans [ABB14], avec la pente de la MDF et les différentes SA. Un vecteur contenant la pente moyenne de la MDF ainsi que quelques SA pourrait servir d'entrée à un algorithme de classification. On pourrait s'attendre à des résultats encore meilleurs que ceux obtenus, mais cela dépend fortement de la corrélation des caractéristiques. Les résultats pourraient venir renforcer l'idée que les matrices permettent d'obtenir de l'information utile.

6.4.2 Filtrage spatial

Le filtrage spatial ayant été utilisé pour les problèmes d'EMG était simplement un différentiel. L'impact de ce différentiel sur la FD et sa SA devraient être étudié. Aussi, une analyse plus approfondie du filtrage spatial en général sur la FD et la SA seraient utiles. Pour l'EMG, on s'attend à ce que différents filtrages ciblent différentes profondeurs et orientations des fibres musculaires. Cela devrait s'analyser premièrement sur des modèles, du plus simple aux plus élaborés. C'est un problème qui s'étudierait bien sur des modèles musculaires tridimensionnels.

6.4.3 Stationnarité

Si la stationnarité a été étudiée par la SA, la séparation de celle-ci avec la non-linéarité demeure non-résolue. On peut imaginer une méthode basée sur la SA qui donnerait un score de non-

linéarité et de non-stationnarité, quoi que la distinction entre les deux puisse être floue par moment.

6.4.4 SA des résidus

Le retrait de la partie linéaire par estimation de modèle ARMA laisse un résidu qui pourrait être étudié par la SA. Est-ce qu'une caractéristique non-linéaire peut être affranchie de l'impact linéaire par cette méthode? Probablement pas, mais dans tous les cas la réponse serait intéressante.

6.4.5 SA et blanchissage des données

Il est généralement admis que le blanchissage des données nuit à l'analyse non-linéaire [THE91]. Une analyse de l'effet du blanchissage des données par la SA pourrait permettre de vérifier si effectivement de l'information se perd lors du filtrage.

6.4.6 SA et filtrage linéaire

D'un point de vue plus large, l'utilisation de filtrage linéaire avec la SA permettrait possiblement d'augmenter la sensibilité de la méthode, de permettre d'éliminer plus de bruit et de cibler seulement certaines bandes de fréquences. Il est cependant probable que les filtres affectant la phase viennent affecter, voire détruire complètement la non-linéarité des signaux. Le problème est bien défini.

6.4.7 Spectre de non-linéarité

Plusieurs méthodes non-linéaires ont un ou plusieurs paramètres. On peut imaginer que le résultat de la SA varie en fonction de ces paramètres. On pourra obtenir un score variant selon

un paramètre, ou un spectre de non-linéarité offrant un portrait plus complet. Une explication plus détaillée de l'idée est présentée à l'Annexe 5..

6.4.8 SA et quantification du signal

Les systèmes de mesure utilisent souvent une arithmétique en virgule fixe et sont généralement quantifiés avec une profondeur relativement limitée. La quantification est une des formes les plus agressives de non-linéarité. Cela peut donc biaiser les résultats de la SA. Dans un contexte d'analyse par SA, [SMA98] avait mentionné un niveau de quantification de 12 bits, comme les systèmes utilisés dans la thèse, sans parler aucunement de l'impact sur les résultats. C'est à-peu-près tout ce qui se trouve sur le lien entre la SA et la quantification dans la littérature. Des tests sur processus ARMA selon la longueur et la largeur de bande seraient appropriés. C'est une problématique très bien définie mais qui reste à explorer.

6.4.9 SA et bruit de mesure

Si l'effet du bruit sur la détection de la non-linéarité a été étudié [POO01], son incidence sur la SA a été peu examinée. Seul [THE92] donne un exemple d'effet du bruit sur la SA. La SA est utilisée généralement pour simplement différencier un signal non-linéaire [THE92][ALL96] et non pour quantifier la proportion de signal non-linéaire dans un bruit. C'est encore un problème assez bien défini.

6.4.10 Effet du fenêtrage selon l'ordre de l'atténuation du processus de l'hypothèse nulle

Le fenêtrage a été étudié dans [SUZ05] et dans les travaux présentés pour des signaux de type AR(1), ayant une atténuation de 20 dB par décade dans la bande d'arrêt. L'effet du fenêtrage provoque un débordement dans la bande d'arrêt. Or, l'effet relatif de ce débordement est d'autant plus fort que la coupure est abrupte. Des essais préliminaires ont montré un biais

accentué pour des ordres d’atténuation supérieurs. Les limites des méthodes de fenêtrage devraient être étudiées. L’étude de la relation est relativement triviale.

6.4.11 SA et PLI

Le retrait de l’interférence du réseau électrique (PLI) pourrait se faire aisément dans le domaine de fréquentiel à même la méthode SA lorsque celle-ci est basée sur la transformée de Fourier. Par contre, plus la fenêtre de données est courte, plus la largeur de bande nécessaire pour le retrait du PLI sera grande. Cette relation devrait être quantifiée, de même que son impact sur la SA.

Une méthode de réduction de l’effet du PLI tirant avantage des matrices de capteurs a été publié [MAN18]. Par contre, il a été décidé de ne pas l’utiliser étant donné le risque d’interactions indésirables avec les caractéristiques non-linéaires. Une étude de ces interactions est nécessaire.

6.5 AXES DE RECHERCHES DÉCOULANT DE LA THÈSE

Pour finir, des nouveaux axes de recherches qui peuvent découler de la thèse ont été identifiées.

- 1) La complémentarité de l’information non-linéaire est maintenant approchable par l’utilisation de la SA. L’interaction entre plusieurs caractéristiques non-linéaires, leurs paramètres et des séries de données non-linéaires peut être étudiée par cette approche.
- 2) L’étude de la vitesse de conduction peut être étudiée par la SA dans les cas où les signaux sont raisonnablement forts, cas non traité jusqu’à présent dans la littérature. Il faut voir maintenant cette relation dans le cadre de modèles de plus en plus raffinés. La question majeure restante est de savoir si à partir de scores de SA il est possible de retrouver les paramètres des différents modèles.

- 3) La recherche d'application de la SA. La SA, sous forme de caractéristique peut être appliquée à tous les domaines utilisant du traitement du signal basé sur des caractéristiques non-linéaires.
- 4) La phase de la transformée de Fourier est souvent ignorées. La SA a montré qu'il est possible d'associer un comportement non-stochastique à celle-ci. C'est une avenue intéressante à poursuivre.
- 5) L'application de la SA au domaine des télécommunications et de radars. Il est facile d'imaginer l'intérêt de la détection de signal de signaux inconnus mais non-aléatoires à ces domaines.

Finalement, si Theiler [THE91] en développant la méthode SA soulignait qu'un but ultime était de comprendre la nature des non-linéarités et de leurs interactions avec les caractéristiques qu'elles influencent ou non. Lorsque les données sont générées par des modèles de séries non-linéaires ou par des fractals bien contrôlés, on peut interpréter assez facilement les résultats des différentes caractéristiques, mais pour des signaux réels, l'interprétation est loin d'être évidente. Bien qu'aucune avancée n'ont été faite dans ce sens, et ce depuis bientôt 30 ans, les travaux présentés dans cette thèse peuvent certainement ouvrir la porte à une meilleure compréhension des phénomènes sous-jacents aux caractéristiques observées.

RÉFÉRENCES

- [ABB14] Abboud, J., Nougarou, F., Pagé, I., Cantin, V., Massicotte, D., & Descarreaux, M. (2014). Trunk motor variability in patients with non-specific chronic low back pain. European journal of applied physiology, 114(12), 2645-2654.
- [ACH05] Acharya, R., Faust, O., Kannathal, N., Chua, T., & Laxminarayan, S. (2005). Non-linear analysis of EEG signals at various sleep stages. Computer methods and programs in biomedicine, 80(1), 37-45.
- [ACH13] Acharya, U. R., Sree, S. V., Swapna, G., Martis, R. J., & Suri, J. S. (2013). Automated EEG analysis of epilepsy: a review. Knowledge-Based Systems, 45, 147-165.
- [ADR33] Adrian, E. D., & Gelfan, S. (1933). Rhythmic activity in skeletal muscle fibres. The Journal of physiology, 78(3), 271-287.
- [ALL96] Allen, M. R., & Smith, L. A. (1996). Monte Carlo SSA: Detecting irregular oscillations in the presence of colored noise. Journal of climate, 9(12), 3373-3404.
- [ALT00] Altman DG, Machin D, Bryant TN, Gardner MJ (Eds) (2000) Statistics with confidence, 2nd ed. BMJ Books. (p. 49)
- [AMM15] Amma, C., Krings, T., Böer, J., & Schultz, T. (2015, April). Advancing muscle-computer interfaces with high-density electromyography. In Proceedings of the 33rd Annual ACM Conference on Human Factors in Computing Systems (pp. 929-938).
- [AND01] Andrzejak, R. G., Lehnertz, K., Mormann, F., Rieke, C., David, P., & Elger, C. E. (2001). Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state. Physical Review E, 64(6), 061907.
- [AND03] Andrzejak, R. G., Kraskov, A., Stögbauer, H., Mormann, F., & Kreuz, T. (2003). Bivariate surrogate techniques: necessity, strengths, and caveats. Physical review E, 68(6), 066202.
- [AND03] Andrzejak, R. G., Mormann, F., Kreuz, T., Rieke, C., Kraskov, A., Elger, C. E., & Lehnertz, K. (2003). Testing the null hypothesis of the nonexistence of a preseizure state. Physical Review E, 67(1), 010901.
- [ASH01] Ashkenazy, Y., Ivanov, P. C., Havlin, S., Peng, C. K., Goldberger, A. L., & Stanley, H. E. (2001). Magnitude and sign correlations in heartbeat fluctuations. Physical Review Letters, 86(9), 1900.
- [BAH74] L.Bahl, J.Cocke, F.Jelinek, and J.Raviv, "Optimal Decoding of Linear Codes for minimizing symbol error rate", IEEE Transactions on Information Theory, vol. IT-20(2), pp. 284-287, March 1974.
- [BAS15] Bastos, A. M., Vezoli, J., & Fries, P. (2015). Communication through coherence with inter-areal delays. Current opinion in neurobiology, 31, 173-180.

- [BEN04] Bennett, M. V., & Zukin, R. S. (2004). Electrical coupling and neuronal synchronization in the mammalian brain. *Neuron*, 41(4), 495-511.
- [BLO00] Bloomfield, P. *Fourier Analysis of Time Series: An Introduction*. New York: Wiley-Interscience, 2000.
- [BOO08] Boonstra, T. W., Daffertshofer, A., Van Diepen, J. C., Van den Heuvel, M. R. C., Hofman, C., Willigenburg, N. W., & Beek, P. J. (2008). Fatigue-related changes in motor-unit synchronization of quadriceps muscles within and across legs. *Journal of Electromyography and Kinesiology*, 18(5), 717-731.
- [BOR10] Borgnat, P., Flandrin, P., Honeine, P., Richard, C., & Xiao, J. (2010). Testing stationarity with surrogates: A time-frequency approach. *Signal Processing, IEEE Transactions on*, 58(7), 3459-3470.
- [BOU95] Bousseljot, R.; Kreiseler, D.; Schnabel, A. Nutzung der EKG-Signalbank CARDIODAT der PTB über das Internet. *Biomedizinische Technik*, Band 40, Ergänzungsband 1 (1995) S 317
- [BOY78] Boyd, D. C., Lawrence, P. D., & Bratty, P. J. (1978). On modeling the single motor unit action potential. *IEEE Transactions on Biomedical Engineering*, (3), 236-243.
- [BRA15] Bradley, E., & Kantz, H. (2015). Nonlinear time-series analysis revisited. *Chaos: An Interdisciplinary Journal of Nonlinear Science*, 25(9), 097610.
- [BRE02] Breakspear, M. (2002). Nonlinear phase desynchronization in human electroencephalographic data. *Human brain mapping*, 15(3), 175-198.
- [BRE03] Breakspear, M., Terry, J. R., Friston, K. J., Harris, A. W. F., Williams, L. M., Brown, K., Gordon, E. (2003). A disturbance of nonlinear interdependence in scalp EEG of subjects with first episode schizophrenia. *Neuroimage*, 20(1), 466-478.
- [BRE05] Breakspear, M., Roberts, J. A., Terry, J. R., Rodrigues, S., Mahant, N., & Robinson, P. A. (2005). A unifying explanation of primary generalized seizures through nonlinear brain modeling and bifurcation analysis. *Cerebral Cortex*, 16(9), 1296-1313.
- [BUL04] Bullmore, E., Fadili, J., Maxim, V., Şendur, L., Whitcher, B., Suckling, J., ... & Breakspear, M. (2004). Wavelets and functional magnetic resonance imaging of the human brain. *Neuroimage*, 23, S234-S249.
- [BUZ03] Buzzi, U. H., Stergiou, N., Kurz, M. J., Hageman, P. A., & Heidel, J. (2003). Nonlinear dynamics indicates aging affects variability during gait. *Clinical biomechanics*, 18(5), 435-443.
- [CAM03] Camastra, F. (2003). Data dimensionality estimation methods: a survey. *Pattern recognition*, 36(12), 2945-2954.
- [CAS06] Castellanos, N. P., & Makarov, V. A. (2006). Recovering EEG brain signals: artifact suppression with wavelet enhanced independent component analysis. *Journal of neuroscience methods*, 158(2), 300-312.

- [CAS10] Castiglioni, P. (2010). What is wrong in Katz's method? Comments on: "A note on fractal dimensions of biomedical waveforms". *Computers in biology and medicine*, 40(11), 950-952.
- [CAZ08] Cazelles, B., Chavez, M., Berteaux, D., Ménard, F., Vik, J. O., Jenouvrier, S., & Stenseth, N. C. (2008). Wavelet analysis of ecological time series. *Oecologia*, 156(2), 287-304.
- [CAZ15] Caza-Szoka, M., Massicotte, D., & Nougarou, F. (2015). Naive Bayesian learning for small training samples: Application on chronic Low Back Pain diagnostic with sEMG sensors. In *Instrumentation and Measurement Technology Conference (I2MTC), 2015 IEEE International* (pp. 470-475). IEEE.
- [CAZ16] Caza-Szoka, M., Massicotte, D., Nougarou, F. & Descarreaux M. (2016). Surrogate Analysis of Fractal Dimensions From Semg Sensor Array as a Predictor of Chronic Low Back Pain. *Engineering in Medicine and Biology Conference (EMBC2016)*, 2016 IEEE International. IEEE.
- [CAZ19] Caza-Szoka, M., Massicotte, D., (2019, May). Detection of Non Random Phase Signal in Additive Noise with Surrogate Analysis. In *2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (Publication acceptée)
- [CAZ20a] Complementarity of Katz's and Higuchi's Fractal Dimension Methods with Application in Surrogate Analysis Based Low Back Pain Detection (Publication à venir)
- [CAZ20b] Windowing Compensation in Fourier Based Surrogate Analysis (Publication à venir)
- [CAZ20c] Sensitivity of the Surrogate Analysis Method to Synchronization and Conduction Velocity of Muscular Fibers (Publication à venir)
- [CHA07] Chan, A. D., & Green, G. C. (2007). Myoelectric control development toolbox. *CMBES Proceedings*, 30.
- [CHE01] Chen, S. H., Lux, T., & Marchesi, M. (2001). Testing for non-linear structure in an artificial financial market. *Journal of Economic Behavior & Organization*, 46(3), 327-342.
- [CLA68] Clark, J., & Plonsey, R. (1968). The extracellular potential field of the single active nerve fiber in a volume conductor. *Biophysical journal*, 8(7), 842.
- [COE14] Coelho, A. L., & Lima, C. A. (2014). Assessing fractal dimension methods as feature extractors for EMG signal classification. *Engineering Applications of Artificial Intelligence*, 36, 81-98.
- [COE14] Coelho, André L. V., et Clodoaldo A. M. Lima. 2014. « Assessing fractal dimension methods as feature extractors for sEMG signal classification ». *Engineering Applications of Artificial Intelligence*, vol. 36, no 0, p. 81-98.
- [COS05] Costa, M., Goldberger, A. L., & Peng, C. K. (2005). Multiscale entropy analysis of biological signals. *Physical review E*, 71(2), 021906.

- [DAK08] Dakos, V., Scheffer, M., van Nes, E. H., Brovkin, V., Petoukhov, V., & Held, H. (2008). Slowing down as an early warning signal for abrupt climate change. *Proceedings of the National Academy of Sciences*, 105(38), 14308-14312.
- [DAK12] Dakos, V., Carpenter, S. R., Brock, W. A., Ellison, A. M., Guttal, V., Ives, A. R., ... & Scheffer, M. (2012). Methods for detecting early warnings of critical transitions in time series illustrated using simulated ecological data. *PloS one*, 7(7), e41010.
- [DAL12] Daley, H., Englehart, K., Hargrove, L., & Kuruganti, U. (2012). High density electromyography data of normally limbed and transradial amputee subjects for multifunction prosthetic control. *Journal of Electromyography and Kinesiology*, 22(3), 478-484.
- [DAT90] Datta, A. K., & Stephens, J. A. (1990). Synchronization of motor unit activity during voluntary contraction in man. *The Journal of physiology*, 422(1), 397-419.
- [DEL06] Del Santo, F., F. Gelli, A. Schmied, J. P. Vedel, A. Rossi et R. Mazzocchio. 2006. « Motor unit synchronous firing as revealed by determinism of surface myoelectric signal ». *Journal of Neuroscience Methods*, vol. 155, no 1, p. 116-121.
- [DEL93] De Luca, Carlo J. 1993. « Use of the surface EMG signal for performance evaluation of back muscles ». *Muscle & Nerve*, vol. 16, no 2, p. 210-216.
- [DIA14] Diab, Ahmad, Mahmoud Hassan, Catherine Marque et Brynjar Karlsson. 2014. « Performance analysis of four nonlinearity analysis methods using a model with variable complexity and application to uterine EMG signals ». *Medical Engineering & Physics*, vol. 36, no 6, p. 761-767.
- [DIN07] Dingwell, J. B., & Kang, H. G. (2007). Differences between local and orbital dynamic stability during human walking. *Journal of biomechanical engineering*, 129(4), 586-593.
- [DOL02] Dolan, K. T., & Neiman, A. (2002). Surrogate analysis of coherent multichannel data. *Physical review E*, 65(2), 026108.
- [DRO06] Drost, Gea, Dick F Stegeman, Baziel GM van Engelen et Machiel J Zwarts. 2006. « Clinical applications of high-density surface EMG: A systematic review ». *Journal of Electromyography and Kinesiology*, vol. 16, no 6, p. 586-602.
- [DUA09] Duann, J. R., Ide, J. S., Luo, X., & Li, C. S. R. (2009). Functional connectivity delineates distinct roles of the inferior frontal cortex and presupplementary motor area in stop signal inhibition. *Journal of Neuroscience*, 29(32), 10171-10179.
- [DUN61] Dunn, Olive Jean (1961). "Multiple comparisons among means". *Journal of the American Statistical Association*. 56 (293): 52–64.
- [FAE04] Faes, L., Pinna, G. D., Porta, A., Maestri, R., & Nollo, G. (2004). Surrogate data analysis for assessing the significance of the coherence function. *IEEE transactions on biomedical engineering*, 51(7), 1156-1166.
- [FAR02] Farina, D., Fattorini, L., Felici, F., & Filligoi, G. (2002). Nonlinear surface EMG analysis to detect changes of motor unit conduction velocity and synchronization. *Journal of Applied Physiology*, 93(5), 1753-1763.

- [FAR02] Farina, Dario, Luigi Fattorini, Francesco Felici et Giancarlo Filligoi. 2002. « Nonlinear surface EMG analysis to detect changes of motor unit conduction velocity and synchronization ». *Journal of Applied Physiology*, vol. 93, no 5, p. 1753-1763.
- [FAR03] Farina, Dario, Marco Gazzoni et Roberto Merletti. 2003. « Assessment of low back muscle fatigue by surface EMG signal analysis: methodological aspects ». *Journal of Electromyography and Kinesiology*, vol. 13, no 4, p. 319-332.
- [FAR04] Farina, D., Mesin, L., Martina, S., & Merletti, R. (2004). A surface EMG generation model with multilayer cylindrical description of the volume conductor. *IEEE Transactions on Biomedical Engineering*, 51(3), 415-426.
- [FAR04] Farina, Dario, Roberto Merletti et Roger M Enoka. 2004. « The extraction of neural strategies from the surface EMG ». *Journal of Applied Physiology*, vol. 96, no 4, p. 1486-1495.
- [FAR15] Farina, D., & Negro, F. (2015). Common synaptic input to motor neurons, motor unit synchronization, and force control. *Exercise and sport sciences reviews*, 43(1), 23-33.
- [FAT05] Fattorini, L., Felici, F., Filligoi, G. C., Traballesi, M., & Farina, D. (2005). Influence of high motor unit synchronization levels on non-linear and spectral variables of the surface EMG. *Journal of neuroscience methods*, 143(2), 133-139.
- [FAU01] Faure, P., & Korn, H. (2001). Is there chaos in the brain? I. Concepts of nonlinear dynamics and methods of investigation. *Comptes Rendus de l'Académie des Sciences-Series III-Sciences de la Vie*, 324(9), 773-793.
- [FIN03] Finneran, Mark T, Daniel Mazanec, Marian E Marsolais, Ernest B Marsolais et William S Pease. 2003. « Large-array surface electromyography in low back pain: a pilot study ». *Spine*, vol. 28, no 13, p. 1447-1454.
- [FRI01] Fries, P., Reynolds, J. H., Rorie, A. E., & Desimone, R. (2001). Modulation of oscillatory neuronal synchronization by selective visual attention. *Science*, 291(5508), 1560-1563
- [FRI12] Fritz, C. O., Morris, P. E., & Richler, J. J. (2012). Effect size estimates: current use, calculations, and interpretation. *Journal of experimental psychology: General*, 141(1), 2.
- [FRI15] Fries, P. (2015). Rhythms for cognition: communication through coherence. *Neuron*, 88(1), 220-235.
- [FUL25] Fulton, J. F., & Liddell, E. G. T. (1925). Electrical responses of extensor muscles during postural (myotatic) contraction. *Proc. R. Soc. Lond. B*, 98(693), 577-589.
- [GEN16] Geng, W., Du, Y., Jin, W., Wei, W., Hu, Y., & Li, J. (2016). Gesture recognition by instantaneous surface EMG images. *Scientific reports*, 6, 36571.
- [GER91] Gerdle, B., Henriksson-Larsen, K., Lorentzon, R., & Wretling, M. L. (1991). Dependence of the mean power frequency of the electromyogram on muscle

- [GOM09] Gómez, C., Mediavilla, Á., Hornero, R., Abásolo, D., & Fernández, A. (2009). Use of the Higuchi's fractal dimension for the analysis of MEG recordings from Alzheimer's disease patients. *Medical engineering and physics*, 31(3), 306-313.
- [GON12] González-Izal, Miriam, Armando Malanda, Esteban Gorostiaga et Mikel Izquierdo. 2012. « Electromyographic models to assess muscle fatigue ». *Journal of Electromyography and Kinesiology*, vol. 22, no 4, p. 501-512.
- [GOU06] Gourévitch, B., Le Bouquin-Jeannès, R., & Faucon, G. (2006). Linear and nonlinear causality between signals: methods, examples and neurophysiological applications. *Biological cybernetics*, 95(4), 349-369.
- [HAH14] J. M. Hahne, et al, “Linear and Nonlinear Regression Techniques for Simultaneous and Proportional Myoelectric Control,” *IEEE Trans Neural Syst Rehabil. Eng.*, Vol. 22, No. 2, pp. 269-79, March 2014.
- [HAM07] Hammond, C., Bergman, H., & Brown, P. (2007). Pathological synchronization in Parkinson's disease: networks, models and treatments. *Trends in neurosciences*, 30(7), 357-364.
- [HAU13] Haufe, S., Nikulin, V. V., Müller, K. R., & Nolte, G. (2013). A critical assessment of connectivity measures for EEG data: a simulation study. *Neuroimage*, 64, 120-133.
- [HEN76] Hénon, M. (1976). A two-dimensional mapping with a strange attractor. In *The Theory of Chaotic Attractors* (pp. 94-102). Springer, New York, NY.
- [HER05] Herrmann, C. S., Grigutsch, M., & Busch, N. A. (2005). 11 EEG oscillations and wavelet analysis. *Event-related potentials: A methods handbook*, 229.
- [HER92] Hermens, H. J., Bruggen, T., Baten, C. T., Rutten, W. L. C., & Boom, H. B. K. (1992). The median frequency of the surface EMG power spectrum in relation to motor unit firing and action potential properties. *Journal of Electromyography and Kinesiology*, 2(1), 15-25.
- [HIG88] Higuchi, T. (1988). Approach to an irregular time series on the basis of the fractal theory. *Physica D: Nonlinear Phenomena*, 31(2), 277-283.
- [HIG88] Higuchi, T. (1988). Approach to an irregular time series on the basis of the fractal theory. *Physica D: Nonlinear Phenomena*, 31(2), 277-283.
- [HIG90] Higuchi, T. (1990). Relationship between the fractal dimension and the power law index for a time series: a numerical investigation. *Physica D: Nonlinear Phenomena*, 46(2), 254-264.
- [HOD52] Hodgkin, A. L., & Huxley, A. F. (1952). A quantitative description of membrane current and its application to conduction and excitation in nerve. *The Journal of physiology*, 117(4), 500-544.2012
- [HOG03] Hogrel, J-Y. 2003. « Use of surface EMG for studying motor unit recruitment during isometric linear force ramp ». *Journal of Electromyography and Kinesiology*, vol. 13, no 5, p. 417-423.

- [HOG05] Hogrel, J. Y. (2005). Clinical applications of surface electromyography in neuromuscular disorders. *Neurophysiologie Clinique/Clinical Neurophysiology*, 35(2-3), 59-71.
- [HOL05] Holtermann, A., Roeleveld, K., & Karlsson, J. S. (2005). Inhomogeneities in muscle activation reveal motor unit recruitment. *Journal of Electromyography and Kinesiology*, 15(2), 131-137.
- [HOR09] Hornero, R., Abásolo, D., Escudero, J., & Gómez, C. (2009). Nonlinear analysis of electroencephalogram and magnetoencephalogram recordings in patients with Alzheimer's disease. *Philosophical Transactions of the Royal Society of London A: Mathematical, Physical and Engineering Sciences*, 367(1887), 317-336.
- [HUA05] Huang, Y., Englehart, K. B., Hudgins, B., & Chan, A. D. (2005). A Gaussian mixture model based classification scheme for myoelectric control of powered upper limb prostheses. *IEEE Transactions on Biomedical Engineering*, 52(11), 1801-1811.
- [HUA09] Huang, He, Ping Zhou, Guanglin Li et Todd Kuiken. 2009. « Spatial filtering improves EMG classification accuracy following targeted muscle reinnervation ». *Annals of biomedical engineering*, vol. 37, no 9, p. 1849-1857.
- [HUD93] Hudgins, B., Parker, P., & Scott, R. N. (1993). A new strategy for multifunction myoelectric control. *IEEE Transactions on Biomedical Engineering*, 40(1), 82-94.
- [HUT04] Hurtado, Jose M, Leonid L Rubchinsky et Karen A Sigvardt. 2004. « Statistical method for detection of phase-locking episodes in neural oscillations ». *Journal of Neurophysiology*, vol. 91, no 4, p. 1883-1898.
- [JEO04] Jeong, J. (2004). EEG dynamics in patients with Alzheimer's disease. *Clinical neurophysiology*, 115(7), 1490-1505.
- [KAM00] Kamen, G., & Roy, A. (2000). Motor unit synchronization in young and elderly adults. *European journal of applied physiology*, 81(5), 403-410.
- [KAT88] Katz, M. J. (1988). Fractals and the analysis of waveforms. *Computers in biology and medicine*, 18(3), 145-156.
- [KAT88] Katz, M. J. (1988). Fractals and the analysis of waveforms. *Computers in biology and medicine*, 18(3), 145-156.
- [KOH95] Kohavi, R. (1995, August). A study of cross-validation and bootstrap for accuracy estimation and model selection. In *Ijcai* (Vol. 14, No. 2, pp. 1137-1145).
- [KON95] König, P., Engel, A. K., Roelfsema, P. R., & Singer, W. (1995). How precise is neuronal synchronization?. *Neural Computation*, 7(3), 469-485.
- [KUM17] Kumawat, B. K., Yadav, R. P., & Salim, M. (2017, October). Analysis of signal processing based spectrum sensing practices in cognitive radio: A review. In *2017 International Conference on Recent Innovations in Signal processing and Embedded Systems (RISE)* (pp. 23-29). IEEE.
- [KUP95] Kupa, E. J., Roy, S. H., Kandarian, S. C., & De Luca, C. J. (1995). Effects of muscle fiber type and size on EMG median frequency and conduction velocity. *Journal of Applied Physiology*, 79(1), 23-32.

- [LAR02] Larivière, C., A. B. Arsenault, D. Gravel, D. Gagnon et P. Loisel. 2002. « Evaluation of measurement strategies to increase the reliability of EMG indices to assess back muscle fatigue and recovery ». *Journal of Electromyography and Kinesiology*, vol. 12, no 2, p. 91-102.
- [LAR03] Larsson, B., Karlsson, S., Eriksson, M.. & Gerdle, B. (2003). Test-retest reliability of EMG and peak torque during repetitive maximum concentric knee extensions. *Journal of Electromyography and Kinesiology*, 13(3), 281-287.
- [LEI01] Lei, M., Wang, Z., & Feng, Z. (2001). Detecting nonlinearity of action surface EMG signal. *Physics Letters A*, 290(5-6), 297-303.
- [LEI01] Lei, M., Wang, Z., & Feng, Z. (2001). Detecting nonlinearity of action surface EMG signal. *Physics Letters A*, 290(5-6), 297-303.
- [LOR63] Lorenz, E. N. (1963). Deterministic nonperiodic flow. *Journal of the atmospheric sciences*, 20(2), 130-141.
- [MAS85] Masuda, Tadashi, Hisao Miyano et Tsugutake Sadoyama. 1985. « A surface electrode array for detecting action potential trains of single motor units ». *Electroencephalography and clinical neurophysiology*, vol. 60, no 5, p. 435-443.
- [MAS86] Masuda, Tadashi, et Tsugutake Sadoyama. 1986. « The propagation of single motor unit action potentials detected by a surface electrode array ». *Electroencephalography and clinical Neurophysiology*, vol. 63, no 6, p. 590-598.
- [MAY04] May, R. M. (2004). Simple mathematical models with very complicated dynamics. In *The Theory of Chaotic Attractors* (pp. 85-93). Springer, New York, NY.
- [MCG88] McGill, K. C., & Huynh, A. (1988, November). A model of the surface-recorded motor-unit action potential. In *Engineering in Medicine and Biology Society, 1988. Proceedings of the Annual International Conference of the IEEE* (pp. 1697-1699). IEEE.
- [MER03] Merletti, Roberto, Dario Farina et Marco Gazzoni. 2003. « The linear electrode array: a useful tool with many applications ». *Journal of Electromyography and Kinesiology*, vol. 13, no 1, p. 37-47.
- [MES09] Mesin, L., Cescon, C., Gazzoni, M., Merletti, R., & Rainoldi, A. (2009). A bi-dimensional index for the selective assessment of myoelectric manifestations of peripheral and central muscle fatigue. *Journal of Electromyography and Kinesiology*, 19(5), 851-863.
- [MES09] Mesin, Luca, Roberto Merletti et A Rainoldi. 2009. « Surface EMG: the issue of electrode location ». *Journal of Electromyography and Kinesiology*, vol. 19, no 5, p. 719-726.
- [MIL73] Milner-Brown, H. S., Stein, R. B., & Yemm, R. (1973). The contractile properties of human motor units during voluntary isometric contractions. *The Journal of physiology*, 228(2), 285-306.
- [MOO66] Moore, G. P., Perkel, D. H., & Segundo, J. P. (1966). Statistical analysis and functional interpretation of neuronal spike data. *Annual review of physiology*, 28(1), 493-522.

- [MOR05] Mormann, F., Kreuz, T., Rieke, C., Andrzejak, R. G., Kraskov, A., David, P., ... & Lehnertz, K. (2005). On the predictability of epileptic seizures. *Clinical neurophysiology*, 116(3), 569-587.
- [NAT04] Natarajan, K., Acharya, R., Alias, F., Tiboleng, T., & Puthusserypady, S. K. (2004). Nonlinear analysis of EEG signals at different mental states. *BioMedical Engineering OnLine*, 3(1), 7.
- [NOR06] Norouzzadeh, P., & Rahmani, B. (2006). A multifractal detrended fluctuation description of Iranian rial-US dollar exchange rate. *Physica A: Statistical Mechanics and its Applications*, 367, 328-336.
- [NOU20] Publication à venir de François Nougarou
- [NUS08] Nussbaum, Maury A. 2008. « Utility of traditional and alternative EMG-based measures of fatigue during low-moderate level isometric efforts ». *Journal of Electromyography and Kinesiology*, vol. 18, no 1, p. 44-53.
- [OST04] Östlund, Nils, Jun Yu, Karin Roeleveld et J Stefan Karlsson. 2004. « Adaptive spatial filtering of multichannel surface electromyogram signals ». *Medical and Biological Engineering and Computing*, vol. 42, no 6, p. 825-831.
- [OSW05] Oświe, P., Kwapien, J., & Drożdż, S. (2005). Multifractality in the stock market: price increments versus waiting times. *Physica A: Statistical Mechanics and its Applications*, 347, 626-638.
- [PER05] Pereda, E., Quiroga, R. Q., & Bhattacharya, J. (2005). Nonlinear multivariate analysis of neurophysiological signals. *Progress in neurobiology*, 77(1-2), 1-37.
- [PIN06] Pincus, S. M. (2006). Approximate entropy as a measure of irregularity for psychiatric serial metrics. *Bipolar disorders*, 8(5p1), 430-440.
- [PLO74] Plonsey, R. (1974). The active fiber in a volume conductor. *IEEE transactions on biomedical engineering*, (5), 371-381.
- [POO01] Poon, C. S., & Barahona, M. (2001). Titration of chaos with added noise. *Proceedings of the National Academy of Sciences*, 98(13), 7107-7112.
- [POR00] Porta, A., Guzzetti, S., Montano, N., Pagani, M., Somers, V., Malliani, A., ... & Cerutti, S. (2000). Information domain analysis of cardiovascular variability signals: evaluation of regularity, synchronisation and co-ordination. *Medical and Biological Engineering and Computing*, 38(2), 180-188.
- [POR01] Porta, A., Guzzetti, S., Montano, N., Furlan, R., Pagani, M., Malliani, A., & Cerutti, S. (2001). Entropy, entropy rate, and pattern classification as tools to typify complexity in short heart period variability series. *IEEE Transactions on Biomedical Engineering*, 48(11), 1282-1291.
- [POR07] Porta, A., Guzzetti, S., Furlan, R., Gnechi-Ruscone, T., Montano, N., & Malliani, A. (2007). Complexity and nonlinearity in short-term heart period variability: comparison of methods based on local nonlinear prediction. *IEEE Transactions on Biomedical Engineering*, 54(1), 94-106.

- [PRI95] Pritchard, W. S., Duke, D. W., & Krieble, K. K. (1995). Dimensional analysis of resting human EEG II: Surrogate-data testing indicates nonlinearity but not low-dimensional chaos. *Psychophysiology*, 32(5), 486-491.
- [RAG09] Raghavendra, B. S., & Dutt, D. N. (2009). A note on fractal dimensions of biomedical waveforms. *Computers in Biology and Medicine*, 39(11), 1006-1012.
- [RAM09] Ramdani, S., Seigle, B., Lagarde, J., Bouchara, F., & Bernard, P. L. (2009). On the use of sample entropy to analyze human postural sway data. *Medical Engineering and Physics*, 31(8), 1023-1031.
- [RAN07] Rankine, L., Stevenson, N., Mesbah, M., & Boashash, B. (2007). A nonstationary model of newborn EEG. *IEEE Transactions on biomedical engineering*, 54(1), 19-28.
- [REG06] Reger, Steven I, Amrik Shah, Thomas C Adams, Jozsef Endredi, Vinoth Ranganathan, Guang H Yue, Vinod Sahgal et Mark T Finneran. 2006. « Classification of large array surface myoelectric potentials from subjects with and without low back pain ». *Journal of Electromyography and Kinesiology*, vol. 16, no 4, p. 392-401.
- [RIL02] Riley, M. A., & Turvey, M. T. (2002). Variability and determinism in motor behavior. *Journal of motor behavior*, 34(2), 99-125.
- [ROG13] Rogers, Daniel R., et Dawn T. MacIsaac. 2013. « A comparison of EMG-based muscle fatigue assessments during dynamic contractions ». *Journal of Electromyography and Kinesiology*, vol. 23, no 5, p. 1004-1011.
- [ROS01] Rosenblum, M., Pikovsky, A., Kurths, J., Schäfer, C., & Tass, P. A. (2001). Phase synchronization: from theory to data analysis. In *Handbook of biological physics* (Vol. 4, pp. 279-321). North-Holland.
- [ROS76] Rössler, O. E. (1976). An equation for continuous chaos. *Physics Letters A*, 57(5), 397-398
- [SAD83] Sadoyama, T, T Masuda et H Miyano. 1983. « Relationships between muscle fibre conduction velocity and frequency parameters of surface EMG during sustained contraction ». *European Journal of Applied Physiology and Occupational Physiology*, vol. 51, no 2, p. 247-256.
- [SCH11] Schmied, Annie, et Martin Descarreaux. 2011. « Reliability of EMG determinism to detect changes in motor unit synchrony and coherence during submaximal contraction ». *Journal of Neuroscience Methods*, vol. 196, no 2, p. 238-246.
- [SCH13] E. Scheme and K. Englehart, “Training strategies for mitigating the effect of proportional control on classification in pattern recognitionbased myoelectric control,” *J. Prosthet. Orthot.*, vol. 25, no. 2, pp. 76–83, Apr. 2013.
- [SEA76] Sears, T. A., & Stagg, D. (1976). Short-term synchronization of intercostal motoneurone activity. *The Journal of physiology*, 263(3), 357-381.
- [SEN68] Sen, Pranab Kumar (1968), "Estimates of the regression coefficient based on Kendall's tau", *Journal of the American Statistical Association*, 63 (324): 1379–1389

- [SHE03] Shen, Y., Olbrich, E., Achermann, P., & Meier, P. F. (2003). Dimensional complexity and spectral properties of the human sleep EEG. *Clinical Neurophysiology*, 114(2), 199-209.
- [SHI10] Shiogai, Y., Stefanovska, A., & McClintock, P. V. E. (2010). Nonlinear dynamics of cardiovascular ageing. *Physics reports*, 488(2-3), 51-110.
- [SMA98] Small, M., & Judd, K. (1998). Correlation dimension: A pivotal statistic for non-constrained realizations of composite hypotheses in surrogate data analysis. *Physica D: Nonlinear Phenomena*, 120(3-4), 386-400.
- [SMI16] L. H. Smith, et al, "Evaluation of Linear Regression Simultaneous Myoelectric Control Using Intramuscular EMG," *IEEE Trans. Biomed. Eng.*, Vol. 63, No. 4, pp. 737–46, April 2016.
- [STA02] Stam, C. J., & Van Dijk, B. W. (2002). Synchronization likelihood: an unbiased measure of generalized synchronization in multivariate data sets. *Physica D: Nonlinear Phenomena*, 163(3-4), 236-251.
- [STA03] Stam, C. J., Breakspear, M., van Walsum, A. M. V. C., & van Dijk, B. W. (2003). Nonlinear synchronization in EEG and whole-head MEG recordings of healthy subjects. *Human brain mapping*, 19(2), 63-78.
- [STA05] Stam, C. J. (2005). Nonlinear dynamical analysis of EEG and MEG: review of an emerging field. *Clinical neurophysiology*, 116(10), 2266-2301.
- [STA05] Staudenmann, Didier, Idsart Kingma, Dick F Stegeman et Jaap H van Dieën. 2005. « Towards optimal multi-channel EMG electrode configurations in muscle force estimation: a high density EMG study ». *Journal of Electromyography and Kinesiology*, vol. 15, no 1, p. 1-11.
- [STE00] Stegeman, D. F., Blok, J. H., Hermens, H. J., & Roeleveld, K. (2000). Surface EMG models: properties and applications. *Journal of Electromyography and Kinesiology*, 10(5), 313-326.
- [STU81] Stulen, F. B., & De Luca, C. J. (1981). Frequency parameters of the myoelectric signal as a measure of muscle conduction velocity. *IEEE Transactions on Biomedical Engineering*, (7), 515-523.
- [SUB10] Subha, D. P., Joseph, P. K., Acharya, R., & Lim, C. M. (2010). EEG signal analysis: a survey. *Journal of medical systems*, 34(2), 195-212.
- [SUN12] Sun, Junfeng, Xiangfei Hong et Shanbao Tong. 2012. « Phase synchronization analysis of EEG signals: an evaluation based on surrogate tests ». *Biomedical Engineering, IEEE Transactions on*, vol. 59, no 8, p. 2254-2263.
- [SUZ05] Suzuki, T., Ikeguchi, T., & Suzuki, M. (2005). Effects of data windows on the methods of surrogate data. *Physical Review E*, 71(5), 056708.
- [SUZ05] T. Suzuki, T. Ikeguchi, and M. Suzuki, "Effects of data windows on the methods of surrogate data," *Physical Review E*, vol. 71, no. 5, 2005.
- [SWA03] Zwarts, Machiel J, et Dick F Stegeman. 2003. « Multichannel surface EMG: basic aspects and clinical utility ». *Muscle & nerve*, vol. 28, no 1, p. 1-17.

- [SWE07] Sweeney-Reed, C. M., & Nasuto, S. J. (2007). A novel approach to the detection of synchronisation in EEG based on empirical mode decomposition. *Journal of computational neuroscience*, 23(1), 79-111.
- [TAY62] Taylor, A. (1962). The significance of grouping of motor unit activity. *The Journal of physiology*, 162(2), 259-269.
- [THE92] J. Theiler, S. Eubank, A. Longtin, B. Galdrikian, and J. D. Farmer, “Testing for nonlinearity in time series: the method of surrogate data,” *Physica D: Nonlinear Phenomena*, vol. 58, no. 1-4, pp. 77–94, 1992.
- [THE92] Theiler, J., Eubank, S., Longtin, A., Galdrikian, B., & Farmer, J. D. (1992). Testing for nonlinearity in time series: the method of surrogate data. *Physica D: Nonlinear Phenomena*, 58(1-4), 77-94.
- [THE92] Theiler, J., Eubank, S., Longtin, A., Galdrikian, B., & Farmer, J. D. (1992). Testing for nonlinearity in time series: the method of surrogate data. *Physica D: Nonlinear Phenomena*, 58(1-4), 77-94.
- [THI06] Thiel, M., Romano, M. C., Kurths, J., Rolfs, M., & Kliegl, R. (2006). Twin surrogates to test for complex synchronisation. *EPL (Europhysics Letters)*, 75(4), 535.
- [TIM98] Timmer, “Power of surrogate data testing with respect to nonstationarity,” *Physical Review E*, vol. 58, no. 4, pp. 5153–5156, Jan. 1998.
- [VIL14] Villarejo, J. J., R. M. Costa, T. Bastos et A. Frizera. 2014. « Identification of low level sEMG signals for individual finger prosthesis ». In Biosignals and Biorobotics Conference (2014): Biosignals and Robotics for Better and Safer Living (BRC), 5th ISSNIP-IEEE. (26-28 May 2014), p. 1-6.
- [WOM07] Womelsdorf, T., Schoffelen, J. M., Oostenveld, R., Singer, W., Desimone, R., Engel, A. K., & Fries, P. (2007). Modulation of neuronal interactions through neuronal synchronization. *science*, 316(5831), 1609-1612.
- [YAO00] Yao, W., Fuglevand, R. J., & Enoka, R. M. (2000). Motor-unit synchronization increases EMG amplitude and decreases force steadiness of simulated contractions. *Journal of Neurophysiology*, 83(1), 441-452.
- [YUE95] Yue, G., Fuglevand, A. J., Nordstrom, M. A., & Enoka, R. M. (1995). Limitations of the surface electromyography technique for estimating motor unit synchronization. *Biological cybernetics*, 73(3), 223-233.
- [ZHO09] Zhou, Ping, Nina L Suresh, Madeleine M Lowery et William Zev Rymer. 2009. « Nonlinear spatial filtering of multichannel surface electromyogram signals during low force contractions ». *Biomedical Engineering, IEEE Transactions on*, vol. 56, no 7, p. 1871-1879.
- [ZHO09] Zhou, W. X. (2009). The components of empirical multifractality in financial returns. *EPL (Europhysics Letters)*, 88(2), 28004.

Annexe 1: APPLICATIONS DE LA SA DANS LA LITTÉRATURE

Cette annexe présente un aperçu de la littérature ayant fait appelle à la SA et montre les domaines d'applications.

Tableau A 1-1 Bibliographie sur les applications de la SA

Référence	Nom de l'article	Année	Citations (mai 2018)	Domaine
[ACH05]	Non-linear analysis of EEG signals at various sleep stage	2005	302	Biomed
[ACH13]	Automated EEG analysis of epilepsy A review	2013	214	Biomed
[AND01]	Surrogate brain activity	2001	1292	Biomed
[AND03]	Bivariate surrogate techniques Necessity and caveats	2003	107	Oscillateurs
[AND03]	Testing the null hypothesis of the nonexistence of a preseizure state2003	2003	115	Biomed
[ASH01]	Magnitude and sign scaling in power law	2001	391	Biomed
[BRA15]	Nonlinear time-series analysis revisited. Chaos: An Interdisciplinary Journal of Nonlinear Science	2015	53	Systèmes dynamiques
[BRE02]	Nonlinear Phase Desynchronization in Human	2002	116	Biomed
[BRE03]	A disturbance of nonlinear interdependence in scalp EEG Schizophrenia	2003	108	Biomed
[BRE05]	A Unifying Explanation of Primary Generalized Seizures Through Nonlinear Brain Modeling	2005	313	Biomed
[BUL04]	Wavelets and functional magnetic resonance imaging of the human brain	2004	209	Biomed
[BUZ03]	Nonlinear dynamics indicates aging affects variability during gait	2003	325	Biomed
[CAM03]	Data Dimensionality Estimation Methods	2003	245	
[CAS06]	Recovering EEG brain signals Artifact suppression with wavelet enhanced independent component analysis	2006	254	Biomed
[CAZ08]	Wavelet analysis of ecological time series	2008	346	Écologie
[CHE01]	Testing for Non-Linear Structure in an artificial financial market	2001	135	Économie
[COS05]	Multiscale-entropy-of-biological-signals	2005	1276	Économie

[DAK08]	Slowing down as an early warning signal for abrupt climate change	2008	512	Écologie
[DAK12]	Methods for Detecting Early Warnings of Critical Transition Ecological Data	2012	293	Écologie
[DIN07]	Differences-Between-Local-and-Orbital-Dynamic-Stability-During-Human-Walking	2007	154	Biomed
[DUA09]	Functional connectivity delineates distinct roles of the inferiorfrontal cortex and	2009	303	Biomed
[FAE04]	Surrogate Data Analysis for Assessing the Significance of the Coherence Function	2004	132	Biomed
[FAU01]	Is there chaos in the brain Concepts of nonlinear	2001	209	Biomed
[GOM09]	Use of the Higuchi's fractal dimension for the analysis of MEG Alzheimer	2009	87	Biomed
[GOU06]	Linear-and-nonlinear-causality-between-signals-Methods-examples-and-neurophysiological-applications	2006	199	Biomed
[HAU13]	A critical assessment of connectivity measures for EEG data	2013	137	Biomed
[HER05]	EEG Oscillations and Wavelet Analysis	2005	196	Biomed
[HOR09]	Nonlinear analysis of electroencephalogram Alzheimer	2009	119	Biomed
[JEO04]	EEG dynamics in patients with Alzheimer's disease	2004	810	Biomed
[LEI01]	Detecting nonlinearity of action surface EMG signal	2001	89	Biomed
[MOR05]	On the predictability of epileptic seizures	2005	409	Biomed
[NAT04]	Nonlinear analysis of EEG signals at different mental states	2004	203	Biomed
[NOR06]	A Multifractal Detrended Fluctuation Description of Iranian Rial-US Dollar Exchange Rate	2006	139	Économie
[OSW05]	Multifractality in the stock market	2005	132	Économie
[PER05]	Nonlinear Multivariate Analysis of Neurophysiological Signal	2005	857	Biomed
[POR00]	Information domain analysis of cardiovascular variability signal	2000	136	Biomed
[POR01]	Entropy-entropy-rate-and-pattern-classification-as-tools-to-typify-complexity-in-short-heart-period-variability-series	2001	293	Biomed
[POR07]	Complexity and Nonlinearity in Short Term Heart Period Variability	2007	113	Biomed

[RAM09]	On the use of sample entropy to analyze human postural sway data	2009	166	Biomed
[RAN07]	A Nonstationary Model of Newborn EEG	2007	107	Biomed
[RIL02]	Variability and Determinism in motor behaviour	2002	377	Biomed
[ROS01]	Phase synchronization from theory to data analysis	2001	364	Oscillateurs
[SHE03]	Dimensional complexity and spectral properties of the human sleep EEG	2003	111	Biomed
[SHI10]	Nonlinear dynamics of cardiovascular ageing	2010	190	Biomed
[STA02]	Synchronization likelihood an unbiased measure of generalized synchronization in multivariate data sets	2002	560	Oscillateurs
[STA03]	Nonlinear Synchronization in EEG and Whole	2003	171	Biomed
[STA05]	Nonlinear dynamical analysis of EEG and MEG Review of an emerging field	2005	973	Biomed
[SUB10]	EEG Signal Analysis: A Survey	2010	194	Biomed
[SWE07]	A novel approach to the detection of synchronisation in EEG based on empirical mode decomposition	2007	148	Biomed
[THI06]	Twin Surrogates to Test for Complex Synchronization	2006	104	Oscillateurs
[ZHO09]	The components of empirical multifractality in financial returns	2009	113	Économie

Annexe 2: CHOIX DU NOMBRE DE SÉRIES DE SUBSTITUTION

Cette annexe présente la relation entre le nombre de séries de substitution et la précision du score Z. On a obtenu les résultats par méthode Monte-Carlo et une approximation lorsque le score est grand par calcul. Les méthodes d'analyse en données de substitution sont longues à appliquer. Par contre, l'objectif est de montrer que la caractéristique sur la série originale est très différente de celles obtenues sur les substitutions. C'est pourquoi le nombre de séries de données de substitution utilisées est généralement limité. Par exemple, on effectue 39 séries de substitution et si la caractéristique de la série originale est hors du domaine des substitutions, la non-linéarité peut être affirmée à 95% de certitude.

Cependant, étant donné qu'on s'intéresse à une mesure de la non-linéarité en tant que caractéristique, le nombre de séries de substitution affecte la précision.

(suite en anglais)

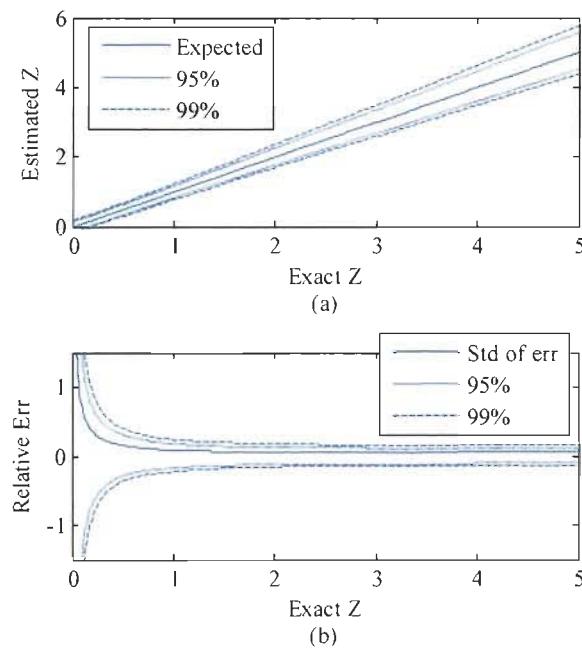


Figure A 2-1 Erreur sur le score de la SA pour 200 séries de substitution

The Z score has a precision affected by numerous factors, one of which is the number of surrogate time series N_s on which the statistics are calculated. The objective of the section is to give a way to choose how many surrogate time series should be made in order to get a certain precision on Z score. The reason why such information is important is because the process of generating the surrogate time series and the calculation of their FD is time consuming. In general, we show that the relative error becomes steady as the Z score takes a large value (in absolute term). Also, because the characteristics used for classifiers are the extreme values of the Z score, it is only the error of these values that are important to evaluate. The approach used in this section is to use Monte-Carlo simulations.

The Monte-Carlo method used here is simply done by generating a certain number of Z scores based on N_s surrogate FD values. The surrogate FD values are simply generated by supposing an i.i.d. standard random normal distribution ($\text{mean} = 0$, $\text{var} = 1$). Hence, from N_s random values, the estimated mean and standard deviation are calculated. This process is repeated a large amount of time (in this case, 20000 times). Then, for a specified difference between the FD of the original series and the theoretical mean of the surrogate FD (noted ΔD), the Z scores are calculated (hence, 20000 Z scores are obtained for 1 value of ΔD). The value of ΔD is varied in small increments. The results are plotted as a function of the exact Z score. Let's note that since we used a standard distribution, the exact Z scores are equal to ΔD . For every exact Z score evaluated, the mean and standard deviations of the estimated Z scores are computed. Also, the estimated Z scores representing the ranks 2.5% and 97.5% of the estimated Z scores for every exact Z score are evaluated, representing an interval comprising 95% of the estimated scores. The same thing is done for the ranks 0.5% and 99.5% for the 99% interval.

We have performed the Monte-Carlo simulation with a number of surrogate FD of 200 ($N_s = 200$), as for all the results presented in this paper. Fig. 12-1(a) presents the range of the estimated Z scores as a function of the exact Z scores. It can be observed that there is no bias in the estimator since the expected estimation is equal to the exact score. However, the range of the estimator varies linearly with the exact score, with an offset at the origin (i.e. there is an affine relation between the range of the estimation and

the exact score). Fig. 12-1(b) shows that the relative error become stable when the exact Z score becomes high. This is because the effect of the error of the mean FD of the surrogate series does not varies with the exact Z score. Also, it can be seen that the errors become stable even when the exact Z score is fairly low. In our works, most of the Z scores used as characteristics were high in absolute value. Hence, the only relative error that needs to be taken into account in the analysis of the choice of N_s is the error at high Z scores. For the settings that were used, the relative errors of the Z scores due to N_s were:

- 11% for 95% confidence interval
- 15% for 99% confidence interval
- a relative standard deviation of 5%

Let's note that the values obtained from the Monte-Carlo method and by the theoretical approach described in the next section were equal. The error caused by the limited number of surrogate series should theoretically worsen the results obtained for classification, being equivalent to multiplicative noise. In other words, the Z scores are multiplied by a number that varies from about 0.9 to 1.1. Hence, the results shown in this paper are conservative with respect to the choice of N_s .

2.1 ANALYTICAL DERIVATION OF THE EFFECT OF THE NUMBER OF SURROGATE SERIES ON THE SCORE Z

This section shows the equations used in the calculation of the standard deviation of the estimated score \hat{Z} with respect to the number of surrogate time series N_s . The estimated score \hat{Z} is calculated from the estimated mean \hat{D}_s and standard deviation $\hat{\sigma}_s$ of the FD obtained for the surrogate data series:

$$\hat{Z} = \frac{D - \hat{D}_s}{\hat{\sigma}_s} \quad (\text{A2-1})$$

Noting the error on the estimated mean ε_s and the difference between the FD of the original series and the exact mean of the FD of the surrogate data series ΔD :

$$\varepsilon_s = \widehat{D}_s - \bar{D}_s, \quad (\text{A2-2})$$

$$\Delta D = D - \bar{D}_s \quad (\text{A2-3})$$

we can rewrite (A2-1) as:

$$\hat{Z} = \frac{\Delta D + \varepsilon_s}{\hat{\sigma}_s} \quad (\text{A2-4})$$

When ΔD is high in comparison to ε_s (i.e. we have $\varepsilon_s \ll |\Delta D|$), \hat{Z} can be approximated by neglecting ε_s :

$$\hat{Z} \approx \frac{\Delta D}{\hat{\sigma}_s} \quad (\text{A2-5})$$

The only statistical variable in the right-hand of the equation (A2-5) is $\hat{\sigma}_s$ which is related to the Chi-Squared law. In the case that:

$$\frac{N_s \hat{\sigma}_s^2}{\sigma_s^2} \sim \chi^2(N_s) \quad (\text{A2-6})$$

the Chi-squared law of order k , $\chi^2(k)$, has an expected value of k and a variance of $2k$. The expectation $E(\hat{Z})$ and standard deviation $Std(\hat{Z})$ are obtained by simple substitution:

$$E(\hat{Z}) \approx E\left(\frac{\Delta D}{\hat{\sigma}_s}\right) = \frac{\Delta D}{E(\hat{\sigma}_s)} = \frac{\Delta D}{\sigma_s} \quad (\text{A2-7})$$

$$Std(\hat{Z}) \approx \frac{\Delta D}{\sqrt{2N_s \sigma_s}} \quad (\text{A2-8})$$

This Chi-square law used in the calculation supposes a normal distribution. Also, Chi-square is not recognized as robust to violation of this hypothesis. However, since N_s is high, this effect is mitigated.

The 95% and 99% confidence intervals can be obtained by replacing $\hat{\sigma}_s$ in eq. (A2-5) by the values obtained from the Chi-square law according to eq. (A2-6).

Annexe 3: ANALYSE DE L'IMPACT DU BIAIS CAUSÉ SUR LA SA PAR LE FENÊTRAGE

Cette annexe étend l'analyse de la cause des biais des 4 méthodes de fenêtrage de la SA. Par un exemple sur un processus AR(1) et en utilisant la SA basée sur la FD d'Higuchi. La suite de l'annexe étant une section retirée de l'article présenté à Annexe 3: (pour alléger l'article), celle-ci est donc rédigée en anglais.

In Figure A 3-1, an example of the original series and surrogate series FDs comparison is made. A histogram of the surrogate FD is first presented. After, the original series FD is put on the same scale. In that case, since the original series FD is clearly within the range of the surrogate FD, the bilateral test would not reject the null hypothesis. The lower part of the figure also illustrates two important characteristics of the surrogate analysis. The first is an offset of the original series with respect to the mean of the surrogate. It is defined as the difference between the original and mean surrogate FDs. The second is the standard deviation of the surrogate FDs which is self-explanatory. These characteristics are important to understand the causes of variation of the FPR.

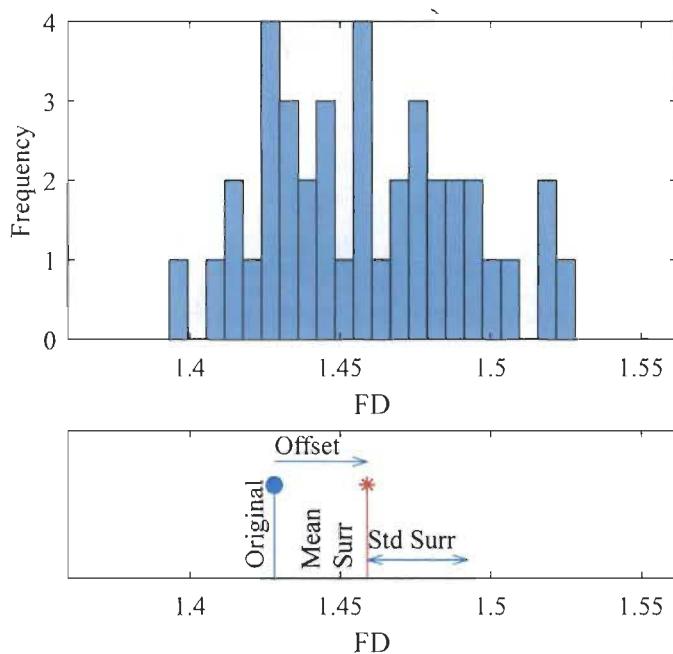


Figure A 3-1 Example of surrogate analysis original and surrogate FD comparison.

When running Monte-Carlo Simulations, both the offset and the surrogate FD standard deviation will vary between the trials. Hence, both will have a certain distribution. The distributions are different for the different systems.

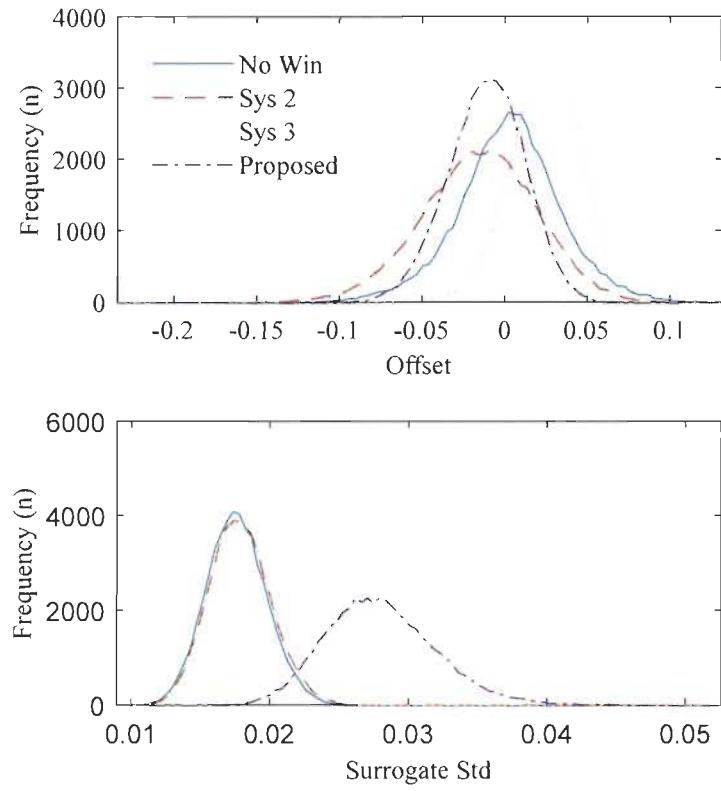


Figure A 3-2 The distribution of the offset and the surrogate FD standard deviation

The distributions of the offset between the FDs of the original series and the mean of the surrogate series is given in Figure A 3-2 (a). The distributions are given for the 4 systems. Here, the ordinate's label “frequency” is used in the distribution sense, the number of occurrences. Each system has a different offset distribution. The distributions are not centered at zero. Hence, the offset has a certain bias. It can be seen that the System 3 has the highest bias. The offset distribution has different standard deviations. The System 1 (no window) and System 2 has the highest standard deviation of the offset. It is however not clear from the graphic how to rank the systems by this measure.

The distribution of the standard deviation of the surrogate's FDs is shown in (b). The systems 1 to 3 have almost the same distribution. However, the proposed System 4 has generally a much wider standard deviation of the surrogate FD, caused by the second stage of windowing which affect randomly the power spectrum.

There is a negative correlation between the offset and the surrogate FD standard deviation up to 0.2. However, it does not modify the conclusions of this paper. It is not obvious to view the relation between the distributions of the offsets and the surrogate FD standard deviation. For this reason, the main statistics of the distributions are reported in Tableau A 3-1. The statistics of the FD of the original series in relation to the FDs of the surrogate series are presented. The Offset represents the difference between the original data (with windowing for Sys 3 and Proposed rows) and the mean FD of the surrogates. The first and second order statistics (means and standard deviations) are normalized with respect to the standard deviation off the FD of the surrogate with no window (Sys 1). Its value was 0.0176. The last row presents the maximum error calculated in the column. The errors are set at 3 times the standard deviation obtained by the bootstrap method with 1000 iterations. The False Positive Rate (FPR) are given for Right-Sided (RS), Left-Sided (LS) and Bilateral tests, with $\alpha_1 = 0.05$. The errors were calculated with the binomial distribution estimation variance with p set at 0.5. Again, the errors were set at 3 standard deviations. The number of tests made was 50000.

Tableau A 3-1 Statistics of the Offset and Surrogate Distributions and False Positive Rates, $a = 0,995$

	Mean Offset	Std Offset	Std Surr	Skew Offset	Skew Surr	Kur Offset	Kur Surr	RS FPR	LS FPR	Bilat FPR
No Win	-0,148	1,819	1,000	0,096	0,142	3,858	2,955	0,124	0,171	0,227
Sys 2	0,901	2,018	1,011	0,198	0,151	3,318	2,964	0,294	0,092	0,308
Sys 3	-1,381	1,186	1,011	0,120	0,151	3,121	2,964	0,007	0,376	0,296
Proposed	0,638	1,328	1,591	0,161	0,201	3,001	2,931	0,061	0,008	0,029

We show that the statistics of the signals and FPRs of the 4 systems. The number of data points per series is 256 and the autoregressive coefficient α_1 is 0.995. Because the higher order statistics are hard to estimate, a large number of tests were made (50000). The precision of the statistics was assessed by bootstrap with 1000 iterations. For FPR, the binomial distribution estimation standard deviation formula was used:

$$\text{std}(e_{FPR}) = \sqrt{p(1-p)/N_{trials}}$$

An upper bound is found by using $p = 0.5$.

The first distribution that is analyzed is that of the difference between the FD of the original signal (possibly windowed) and the mean of the FD of the surrogate distribution. We call this difference an offset. The second distribution is that of the FD of the surrogate.

The absolute value of the offset is in itself uninteresting in the surrogate analysis context. It must be compared to the surrogate distribution in order to be meaningful. A perfectly fair offset distribution should have a mean of 0 and a standard deviation equal to that of the surrogate. Moreover, the higher order statistics (Skewness and Kurtosis) should match those of the surrogate distribution. A system ideal as described should have a 0.05 FPR. Any discrepancy of these relations will affect the FPR. What follows discusses the effect of those discrepancy.

- *Effect of the Mean*

A non-null mean of the offset will increase either of the RS or LS FPR, while reducing the other. The Bilateral FPS will also be increased.

- *Effect of the Standard Deviation*

When the standard deviation of the offset increases, all the FPR increase.

- *Effect of the Skewness*

The skewness will increase either of the RS or LS FPR and increase. The Bilateral FPS will also be increased.

- *Effect of the Kurtosis*

The Kurtosis affects both RS and LS FPR equally. The higher the Kurtosis, the larger the tails. The Bilateral FPS will be modified in the same manner.

For the higher order statistics, the effects are not general in the sense that it is possible to construct distributions that contradicts the tendencies given. However, for the context of the signals used in this paper where the distributions have only slight deviation from the normal distribution, these tendencies are reasonable. Also, the different discrepancies interact with each other in non-trivial, nonlinear ways.

The variability of the different statistics was unexpectedly low. Particularly, the standard deviations of the FD of the surrogate data were of the order of 0.02, which is small considering that the FDs calculated by Higuchi's method generally fall between 1 and 2. To facilitate the readings of the table and the comparison between the different systems, all the first order statistics were normalized by the standard deviation of the FD of the surrogate data obtained without windowing (System 1). The value of the normalization was 0.0176.

The following section describes the impact of the windowing on the different first and second order statistics and FPRs. It is important to note that these observations are good for signals of type AR(1) with $\alpha_l = 0.995$, $N_{data} = 256$ and systems using Higuchi's FD with the same parameter as in the simulation, the Welch's window, and a significance level $\alpha = 0.05$. The importance of each effect will vary when changing either the signal or the system. With each signal or parameter, a new impact of the windowing should be done. Nonetheless, the impact of the different statistics is resumed simply in the FPR.

- *No Windowing (System 1)*

To analyze the system without windowing, a rectangular window should be considered. This window has no time-varying aspects, but a high impact on the surrogate power spectrum. Also, the periodic extension has a high impact on the offset. However, in this paper, we haven't tackled the problem of separating the effect of the two causes.

- *Windowing before FFT (System 2)*

When windowing is applied before the FFT, the effect on the power spectrum is constant. Hence, it will have a constant effect on the surrogate distribution, modifying the Offset's distribution, but not the

standard deviation of the surrogate's distribution. This is shown by a strong increase in the mean and standard distribution of the offset but not the standard deviation of the surrogate distribution. It must be said that although the FPR of the left-sided test is reduced in comparison to the System 1, it is caused by the mean offset which acts as a bias. Meanwhile, the right-sided and bilateral tests are strongly biased for the same reason.

- *Windowing on Original Data and Before FFT (System 3)*

The windowing of the original data adds a bias to the FD of the original data which translates in a larger (in absolute value) mean offset. However, it nullifies the difference in power spectrum between the original and surrogates series. There is therefore a much smaller offset standard deviation. Principally caused by the mean offset, the FPR is much stronger for the Left-Sided than the Right-Sided test. The Bilateral test is also strongly affected.

- *Windowing on Original Data, Before and After FFT (Proposed System 4)*

With the proposed system, the same time varying effect from the windowing is present in the original and surrogate series. There is on the other hand a difference between their Power Spectrums. However, this difference is caused by the windowing done after the surrogate phase randomization. Hence, it is not constant between surrogates. This explains why the standard deviation of the surrogate's FDs is raised. Because the standard deviation of the surrogate is in the comparable to the combined effect of the offset's mean and standard deviation, the FPR are all close or under 0.05. This allowed to give a conservative bilateral test.

While no attempts have been made to interpret the effect of higher order statistics, it can be seen that besides the Kurtosis of the surrogate's distribution, there is a certain variation between the systems. Higher order statistics often has a significant impact on the tails. It is hence important to keep in mind that there can be an important effect caused by the non-normal nature of the involved distributions.

Annexe 4: EFFET DE LA RÉPARTITION ALÉATOIRE DES DONNÉES SUR LA VALIDATION CROISÉE

Cette annexe montre comment la répartition aléatoire des données entre les groupes d'entraînement, validation et test peut mener à des résultats de beaucoup trop optimistes. Il y a en tout 51 expériences de 15 mouvements ayant 40 fenêtres utiles (total de 30600 fenêtres) qui doivent être réparties dans les trois groupes. On fait ici l'analyse de trois approches alternatives de répartition des données qui

- 1) Répartition aléatoire des fenêtres individuelles
- 2) Répartition aléatoire des mouvements : les groupes de 40 fenêtres consécutives appartenant au même mouvement sont distribués au même groupe
- 3) Répartition aléatoire des expériences : chaque suite de 15 mouvements consistant de 600 fenêtres est attribuée au même groupe.

On a ici de bien meilleures performances sur le groupe test que celles décrites plus tôt. Des performances sous la barre des 1% sont souvent trouvées, et ce sans filtre médian. On remarquera aussi la grande similarité entre les performances sur les trois groupes. Ces approches surestiment les performances réelles étant donné qu'elles réduisent l'impact de la non-stationnarité temporelle.

Il est encourageant qu'un seul réseau de neurone puisse séparer les mouvements sur une longue période de temps. Cela signifie qu'il existe au moins une fonction qui peut séparer toutes les données sans confusion malgré une non-stationnarité. Aussi, les performances d'un système adaptatif pourraient ressembler à ce qui est présenté puisque l'extrapolation est à court terme. Il est à noter que le mouvement 2 est correctement détecté selon les trois approches. Il est plausible que la non-stationnarité soit plus forte pour ce mouvement.

Dans la littérature, on omet souvent l'impact de la non-stationnarité. Par exemple, dans [AMM15] et [GEN16], une validation croisée de type « *k-fold* » est utilisée. Celle-ci est similaire à la répartition

aléatoire des expériences. Il est possible que les expérimentations dans ces cas aient été faites sur de relativement courtes durées et qu'ainsi l'impact de la non-stationnarité soit négligeable, mais il est probable que les performances devraient être réduites comme cela a été fait ici. Une étude complète de l'impact des méthodes de validation croisée pourrait jeter un nouvel éclairage sur la littérature actuelle.

Tableau A 4-1 Résultat pour répartition aléatoire entre les groupes, fenêtre par fenêtre

VAR	MDF	FD Higuchi	FD Katz	Z Higuchi	Z Katz	Avec		Avec		Avec		Sans	Sans	Sans
						Mouvement 2 Entrainement	Mouvement 2 Validation	Mouvement 2 Test	Mouvement 2 Entrainement	Mouvement 2 Validation	Mouvement 2 Test			
1	0	0	0	0	0	0.0569	0.0580	0.0556	0.0755	0.0781	0.0787			
0	1	0	0	0	0	0.0103	0.0259	0.0234	0.0116	0.0233	0.0229			
0	0	1	0	0	0	0.0098	0.0252	0.0251	0.0088	0.0225	0.0198			
0	0	0	1	0	0	0.0093	0.0266	0.0287	0.0064	0.0256	0.0237			
0	0	0	0	1	0	0.2929	0.3506	0.3452	0.2498	0.3071	0.3147			
0	0	0	0	0	1	0.2583	0.2873	0.2917	0.2213	0.2679	0.2635			
1	1	0	0	0	0	0.0069	0.0177	0.0159	0.0042	0.0140	0.0149			
0	1	1	0	0	0	0.0021	0.0122	0.0127	0.0025	0.0104	0.0100			
0	1	0	1	0	0	0.0004	0.0093	0.0082	0.0004	0.0069	0.0076			
0	1	0	0	1	0	0.0135	0.0292	0.0285	0.0084	0.0218	0.0236			
0	1	0	0	0	1	0.0048	0.0204	0.0216	0.0054	0.0178	0.0183			
0	0	1	1	0	0	0.0017	0.0104	0.0104	0	0.0078	0.0066			
0	0	0	0	1	1	0.1178	0.1639	0.1669	0.0897	0.1379	0.1389			
0	1	1	1	0	0	0.0024	0.0075	0.0062	0	0.0047	0.0056			
0	1	0	0	1	1	0.0025	0.0186	0.0195	0.0031	0.0168	0.0183			
0	1	0	0	1	1	0.0027	0.0195	0.0213	0.0021	0.0168	0.0194			
0	1	1	0	1	0	0.0027	0.0146	0.0132	0.0024	0.0126	0.0093			
0	1	0	1	0	1	0	0.0075	0.0075	0.0007	0.0071	0.0068			
1	1	1	1	0	0	0	0.0058	0.0048	0.0002	0.0040	0.0049			
1	1	1	0	1	0	0.0002	0.0091	0.0081	0.0015	0.0097	0.0096			
1	1	0	1	0	1	0	0.0049	0.0050	0	0.0036	0.0056			
0	1	1	1	1	1	0	0.0044	0.0062	0	0.0045	0.0048			
1	1	1	1	1	1	0	0.0055	0.0051	0	0.0057	0.0046			

Tableau A 4-2 Résultat pour répartition aléatoire entre les groupes, mouvement par mouvement

VAR	MDF	FD Higuchi		FD Katz		Avec Mouvement 2	Avec Entrainement	Avec Validation	Test	Sans Mouvement 2	Sans Entrainement	Sans Validation	Sans Test
		Z Higuchi	Z Katz	Z Higuchi	Z Katz								
1	0	0	0	0	0	0.0618	0.0935	0.1152	0.1509	0.1631	0.1619		
0	1	0	0	0	0	0.0095	0.0288	0.0287	0.0093	0.0290	0.0286		
0	0	1	0	0	0	0.0129	0.0346	0.0334	0.0119	0.0268	0.0285		
0	0	0	1	0	0	0.0207	0.0385	0.0354	0.0100	0.0306	0.0301		
0	0	0	0	1	0	0.2911	0.3748	0.3513	0.2673	0.3273	0.3295		
0	0	0	0	0	1	0.2407	0.3206	0.3116	0.2265	0.2751	0.2925		
1	1	0	0	0	0	0.0047	0.0215	0.0249	0.0063	0.0282	0.0204		
0	1	1	0	0	0	0.0037	0.0155	0.0209	0.0041	0.0176	0.0144		
0	1	0	1	0	0	0.0014	0.0146	0.0151	0	0.0078	0.0107		
0	1	0	0	1	0	0.0107	0.0279	0.0352	0.0086	0.0273	0.0300		
0	1	0	0	0	1	0.0067	0.0248	0.0286	0.0022	0.0325	0.0245		
0	0	1	1	0	0	0.0072	0.0217	0.0194	0	0.0107	0.0109		
0	0	0	0	1	1	0.1288	0.1967	0.1819	0.0909	0.1671	0.1607		
0	1	1	1	0	0	0.0009	0.0104	0.0112	0	0.0057	0.0121		
0	1	0	0	1	1	0.0007	0.0228	0.0297	0.0043	0.0266	0.0280		
0	1	0	0	1	1	0.0059	0.0246	0.0273	0.0029	0.0197	0.0200		
0	1	1	0	1	0	0.0038	0.0199	0.0163	0.0012	0.0102	0.0154		
0	1	0	1	0	1	0	0.0155	0.0145	0	0.0066	0.0073		
1	1	1	1	0	0	0	0.0069	0.0083	0.0001	0.0102	0.0074		
1	1	1	0	1	0	0.0004	0.0155	0.0141	0.0006	0.0145	0.0131		
1	1	0	1	0	1	0.0010	0.0100	0.0154	0.0006	0.0114	0.0095		
0	1	1	1	1	1	0.0005	0.0137	0.0127	0.0015	0.0102	0.0083		
1	1	1	1	1	1	0.0002	0.0093	0.0091	0	0.0088	0.0069		

Tableau A 4-3 Répartition aléatoire entre les groupes, expérience par expérience

VAR	MDF	FD Higuchi	FD Katz	Z Higuchi	Z Katz	Avec	Avec	Avec	Sans	Sans	Sans
						Mouvement 2 Entrainement	Mouvement 2 Validation	Mouvement 2 Test	Mouvement 2 Entrainement	Mouvement 2 Validation	Mouvement 2 Test
1	0	0	0	0	0	0.0516	0.0729	0.0632	0.0624	0.0674	0.0683
0	1	0	0	0	0	0.0049	0.0275	0.0273	0.0110	0.0249	0.0218
0	0	1	0	0	0	0.0047	0.0233	0.0277	0.0064	0.0209	0.0180
0	0	0	1	0	0	0.0211	0.0383	0.0364	0.0061	0.0195	0.0158
0	0	0	0	1	0	0.2079	0.3183	0.3426	0.2291	0.2867	0.2880
0	0	0	0	0	1	0.2162	0.2895	0.2980	0.2562	0.3031	0.2990
1	1	0	0	0	0	0.0028	0.0226	0.0209	0.0035	0.0147	0.0129
0	1	1	0	0	0	0.0025	0.0153	0.0136	0.0005	0.0102	0.0096
0	1	0	1	0	0	0.0043	0.0153	0.0135	0	0.0057	0.0053
0	1	0	0	1	0	0.0019	0.0246	0.0240	0.0009	0.0204	0.0131
0	1	0	0	0	1	0.0033	0.0228	0.0215	0.0008	0.0161	0.0138
0	0	1	1	0	0	0.0025	0.0133	0.0138	0	0.0081	0.0061
0	0	0	0	1	1	0.0998	0.1655	0.1707	0.0704	0.1249	0.1189
0	1	1	1	0	0	0.0020	0.0109	0.0104	0	0.0066	0.0050
0	1	0	0	1	1	0.0024	0.0184	0.0189	0.0005	0.0180	0.0119
0	1	0	0	1	1	0.0014	0.0195	0.0183	0.0021	0.0180	0.0125
0	1	1	0	1	0	0.0030	0.0157	0.0147	0.0001	0.0133	0.0092
0	1	0	1	0	1	0	0.0109	0.0084	0.0732	0.0726	0.0765
1	1	1	1	0	0	0.0028	0.0091	0.0093	0	0.0064	0.0049
1	1	1	0	1	0	0.0005	0.0126	0.0119	0	0.0081	0.0062
1	1	0	1	0	1	0.0003	0.0086	0.0074	0	0.0040	0.0034
0	1	1	1	1	1	0.0012	0.0097	0.0096	0	0.0064	0.0044
1	1	1	1	1	1	0	0.0075	0.0073	0	0.0062	0.0037

Annexe 5: ANALYSE DE DONNÉES DE SUBSTITUTION DU SPECTRE DE LA LONGUEUR DE COURBE SOUS-ÉCHANTILLONNÉ

Cette annexe a pour but de montrer la généralisation du lien entre les méthodes de Katz et d'Higuchi utilisées dans la SA. On observe une courbe du spectre de la longueur de courbe sous-échantillonnée pour montrer qu'une approche multivariée associée aux données de substitution pourrait offrir une méthode de détection des non-linéarités plus sensible que par l'utilisation des méthodes de calcul de dimensions fractales. L'approche est entièrement originale.

Le spectre de la longueur de courbe sous-échantillonné $L(k)$ est une étape du calcul de la dimension fractale selon la méthode d'Higuchi. Sous représentation doublement logarithmique, la pente est la dimension fractale. Aussi, nous avons démontré que $L(1)$ est lié à la méthode de Katz. Or, les deux méthodes fractales ont été montrées complémentaires lors de nos tests de classification LBP/contrôle avec l'utilisation de données de substitution. On peut donc supposer que $L(1)$ et la pente de $L(k)$ sont deux sources d'information pertinentes.

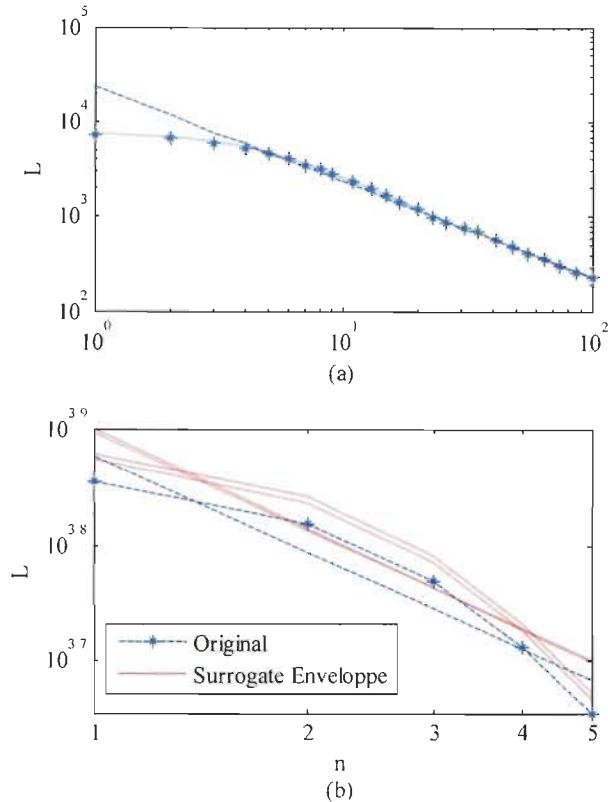


Figure A 5-1 Spectre de la longueur de courbe sous-échantillonnée

Le spectre de la longueur de courbe sous-échantillonné $L(n)$ est présenté à la figure précédente. Le graphique présenté en (a) inclut une vue étendue du spectre d'un canal EMG et des séries de substitution. La ligne droite pointillée est le spectre L d'un bruit blanc ($FD = 1.5$), donnée pour mettre en évidence l'impact de l'autocorrélation du signal. Les autres courbes montrent les résultats pour les données de substitution et la série originale. Il est clair que les courbes sont très près les unes des autres. Le graphique (b) montre le détail du spectre où on calcule la dimension fractale. Pour les données de substitution, seule l'enveloppe est montrée. Les droites montrent la régression du spectre appliquée sur l'intervalle $k = 1..5$. Pour les données de substitution, les droites de régression montrées sont celles ayant les courbes maximales et minimales (et donc les dimensions fractales minimales et maximales).

Dans cet exemple de spectre d'un signal EMG, on remarque que les courbes sont clairement non-linéaires. La dimension fractale (pente) selon Higuchi ne représente donc qu'une faible partie de

l'information. De plus, la différence entre la courbe de la série originale et celles des données de substitution est encore moins bien expliquée par la pente. Cependant, L(1) présente clairement une différence.

En observant les courbes, on en vient à se poser la question si une comparaison du spectre des données originales avec une distribution multivariée du spectre des données de substitution permettait une meilleure sensibilité aux non-linéarités.

Pour notre application, cela apporterait une seule caractéristique au lieu des deux dimensions fractales. Sans nécessairement contenir toute l'information, on peut espérer qu'elle ait de meilleures performances que les deux individuellement.

On peut aussi entrevoir que la méthode serait moins sensible à la sélection de paramètres arbitraires, tels que le sous-échantillonnage maximal et les pas de sous-échantillonnages. Des sous-échantillonnages sans intérêt auraient à la rigueur principalement comme effet d'augmenter possiblement le nombre de données de substitution nécessaires pour une certaine précision.

Notons que la portée de ce développement serait beaucoup plus large que pour le sujet des signaux EMG.

Annexe 6: PUBLICATIONS

Les publications réalisées, acceptées et à venir dans la thèse sont présentées de manière chronologique :

- [CAZ15] Caza-Szoka, M., Massicotte, D., & Nougarou, F. (2015, May). Naive Bayesian learning for small training samples: Application on chronic Low Back Pain diagnostic with sEMG sensors. In *2015 IEEE International Instrumentation and Measurement Technology Conference (I2MTC) Proceedings* (pp. 470-475). IEEE.
- [CAZ16] Caza-Szoka, M., Massicotte, D., Nougarou, F., & Descarreux, M. (2016, August). Surrogate analysis of fractal dimensions from SEMG sensor array as a predictor of chronic low back pain. In *2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* (pp. 6409-6412). IEEE.
- [CAZ18] Caza-Szoka, M., Massicotte, D., & Nougarou, F. (2018, June). Beamforming for Powerline Interference in Large Sensor Arrays. In *2018 16th IEEE International New Circuits and Systems Conference (NEWCAS)* (pp. 269-272). IEEE.
- [CAZ19] Caza-Szoka, M., Massicotte, D., (2019, May). Detection of Non Random Phase Signal in Additive Noise with Surrogate Analysis. In *2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*.
- [CAZ20a] Complementarity of Katz's and Higuchi's Fractal Dimension Methods with Application in Surrogate Analysis Based Low Back Pain Detection (*Publication à venir*)
- [CAZ20b] Windowing Compensation in Fourier Based Surrogate Analysis (*Publication à venir*)
- [CAZ20c] Sensitivity of the Surrogate Analysis Method to Synchronization and Conduction Velocity of Muscular Fibers (*Publication à venir*)

Annexe 7: CODE MATLAB® POUR LA SA ET LES FDS

Cette annexe présente les codes Matlab® pour les données de substitutions de la SA et les dimensions fractales selon Higuchi et Katz.

7.1 CODE DE LA SA

La fonction `surrogate` permet d'obtenir une série de substitution. Notons que celle-ci peut être modifiée aisément pour produire plusieurs séries, ce qui évite de produire plusieurs transformées de Fourier de la série originale.

```
function [ DataSurrogate ] = surrogate( Data )
%SURROGATE Randomnize the phase of the data

len_Data = length(Data);
if mod(len_Data,2)
    dephasageGen = exp(2j*pi*rand(1,len_Data/2-.5));
    dephasage = [(rand(1)>.5)*2-1 dephasageGen conj(dephasageGen(end:-1:1))]';
    DataSurrogate = real(ifft(fft(Data).*dephasage));
else
    dephasageGen = exp(2j*pi*rand(1,len_Data/2 - 1));
    dephasage = [(rand(1)>.5)*2-1 dephasageGen (rand(1)>.5)*2-1 ...
        conj(dephasageGen(end:-1:1))]';
    DataSurrogate = real(ifft(fft(Data).*dephasage));
end
end
```

7.2 CODE DES DIMENSIONS FRACTALES

Les deux fonctions suivantes montrent les calculs des FDs selon Higuchi et Katz respectivement.

```
function [D] = Higuchi( Data, k_vec )
    N = length(Data);
    k_len = length(k_vec);

    L_k = zeros(k_len,1);
    for k_ind = 1:k_len
        for m_ind = 1:k_vec(k_ind)
            floorN_moins_m_sur_k = floor((N-m_ind)/k_vec(k_ind));
            Data_m_k = Data(m_ind:k_vec(k_ind):end);
            L_k(k_ind) = L_k(k_ind)+sum(abs(Data_m_k(2:end) - ...
            Data_m_k(1:end-1)))*(N-1)/(floorN_moins_m_sur_k*k_vec(k_ind));
        end
        L_k(k_ind) = L_k(k_ind)/k_vec(k_ind).^2;
    end

    pol = polyfit(log(k_vec)',log(L_k),1);

    D = -pol(1);
end

function [ Katz_D ] = Katz( data, time_scale )
    len_data = length(data);

    d = sqrt(max((data(2:end)-data(1)).^2+(1:len_data-1).^2*time_scale.^2));
    L = sum(sqrt((data(2:end)-data(1:end-1)).^2 + time_scale.^2));

    Katz_D = log(len_data)./(log(len_data)+log(d./L));
end
```

NAIVE BAYESIAN LEARNING FOR SMALL TRAINING SAMPLES: APPLICATION ON CHRONIC LOW BACK PAIN DIAGNOSTIC WITH SEMG SENSORS

Manouane Caza-Szoka, Daniel Massicotte, François Nougarou

Université du Québec à Trois-Rivières, Electrical and Computer Engineering Department
C.P. 500, Trois-Rivières, Québec, Canada, G9A 5H7, www.uqtr.ca/LSSI
{manouane.caza-szoka, daniel.massicotte, francois.nougarou}@uqtr.ca

ABSTRACT

This paper presents a method to classify chronic Low Back Pain subject by analyzing the muscular fatigue. A new signal characteristic is introduced: the spatial distribution of the Median Frequency slope. Because of the high number of sensors relative to the number of subjects tested, the classification method used is the Naive Bayesian classifier. The low back muscular fatigue is measured by the use of a matrix of 60 surface electromyography sensors. A total of 65 subjects comprising 43 with chronic low back pain condition and 22 healthy have performed a Sorenson test to produce fatigue on *lumbar erector spinae* muscles. A success rate of almost 70% cross-validated by a leave-one-out method is reported. The statistical significance of this success rate is evaluated by a permutation method.

Index Terms— *sEMG, LBP, CLBP, Fatigue, MDF, Naive Bayesian, Classification, Multi-Variable Analysis, High Dimensionality.*

1. INTRODUCTION

The chronic Low-Back Pain (LBP) is the most prevalent musculoskeletal condition [1] and the use of surface electromyography (sEMG) in LBP is an active research domain. The detection of LBP condition with the use of sEMG is an active research axis [2],[3],[4]. However these methods are based on dynamical tasks, i.e. the subjects are moving while the recording is performed. The movements produced involve a large quantity of muscles through the whole body. The results of these methods could be strongly influenced by injuries that are not related to the low-back region. This paper concentrates another approach which is to study the muscular fatigue during a static task which involves mainly muscle of the back. The median frequency (MDF) is related to the muscular fatigue. The relation between MDF and fatigue has been known for a long time and has been studied extensively [5],[6]. The relation is that there is a compression of the power spectrum that comes with fatigue.

On simple muscle such as the *biceps brachii*, the relation is very obvious. However, the low back is a system of complex muscles arranged in different layers with multiple origins and insertion points and a distributed network of innervation. For these reasons, the reliability of the relation between MDF and fatigue in the low-back region has been done by numerous research groups such as in [7],[8],[9].

These studies showed that the MDF is a reliable measure in the low-back region.

The idea of detecting LBP condition by using the MDF as a discriminant has been evaluated in [10]. There has been found a significant difference between LBP and control groups, but not sufficiently high to be used as a linear discriminant. Since the MDF slope of a single location does not allow classification of LBP subjects on an individual basis, using multiple sensors is the natural next step. Papers showing good classification results using this approach have been presented in [11],[12], but the classification performances were established solely on the training data, with low number of subjects and high number of data. Under those circumstances, it is impossible to confirm the validity of the results without any proper cross-validation method. Thus, it brought the idea of using multiple measurements of MDF slope to improve the classification.

In this paper, we propose to apply large matrices of sEMG sensors in order to extract more information about the muscular fatigue of the lumbar region. Also, a new metric is introduced to extract the spatial distribution of the fatigue. The treatment of this high quantity of information is a non-trivial task. The dimensionality of the measurements is high in comparison to the number of subjects studied. This problem is known as Hughes phenomenon or “the curse of dimensionality” [13]. Most of machine learning algorithms necessitate three groups of data, namely a training set, a validation set and a test set. The different adjustment of all the parameters and choices of structure should be made without the use of the test set, which is reserved for performance evaluation. However, on small datasets, it is impossible to obtain those three sets. The leave-one-out method can be used to avoid this problem, but applying it two times makes the calculation prohibitive.

The Naïve Bayesian Classifier has the advantage to avoid the necessity of adjusting free parameters. Moreover, the method is well recognised for its robustness [14]. These aspects will be highlighted in this paper.

The paper is organized as follows; the system, procedure and classification method is presented in Section 2 while its analysis method is postponed in Section 3. The experimental results are reported and discussed in Section 4. Finally, Section 5 draws some brief conclusions.

2. SYSTEM AND PROPOSED METHODS

This section describes the measures taken, the extraction of the signal characteristics and the classification method.

A) Measurement System, Task and Group Studied

The measurement system uses 2 sensor matrices that cover a large area of the low back with a relatively low spacing. The matrices are composed of 5x13 sEMG electrodes' matrix (12.5mm inter-electrode distance (IED), OT Bioelettronica, Italy), which gives 5x12 differential measurements. These matrices are close to the *lumbar erector spinae* muscles in order to study its neuromuscular strategy during an endurance task. A total of 65 subjects comprising 43 with chronic low back pain condition and 22 healthy were studied. The subjects performed a Sorensen task [15] with a 30% of maximal force load. The sampling frequency was 2048 Hz.

B) Extraction of the Fatigue Spatial Distribution

This subsection presents a new signal characteristic: the spatial distribution of the MDF slope. It is related to the spatial distribution of the muscular fatigue. The extraction of the characteristic process is shown in Fig. 1, as well as the classification method which is presented later.

First, the data series $u_{n,m}$, where n is the number of the sensor and m is the number of the subject, are windowed by using a rectangular window in order to obtain $w_{n,m}$:

$$w_{n,m}(k,t) = u_{n,m} \left(\frac{k-1}{2} + t \right) * rect(2t + .5) \quad (1)$$

where $rect$ is a rectangular function with a value of 1 between ± 0.5 and 0 otherwise. The size of the window is 0.5 seconds. The Fast Fourier Transform (FFT) is applied on the different windows:

$$W_{n,m}(k,f) = FFT(w_{n,m}(k,t)) \quad (2)$$

For each $W_{n,m}(k,f)$, the median frequency (MDF) is calculated as following:

$$v_{n,m}(k) = MDF(W_{n,m}(k,f)) \quad (3)$$

The MDF is defined by the frequency at which the power of lower frequency is 50% of the total power. For each sensor, $v_{n,m}$ is approximated by a linear function.

$$\hat{v}_{n,m}(k) = a_{n,m}k + b_{n,m} \quad (4)$$

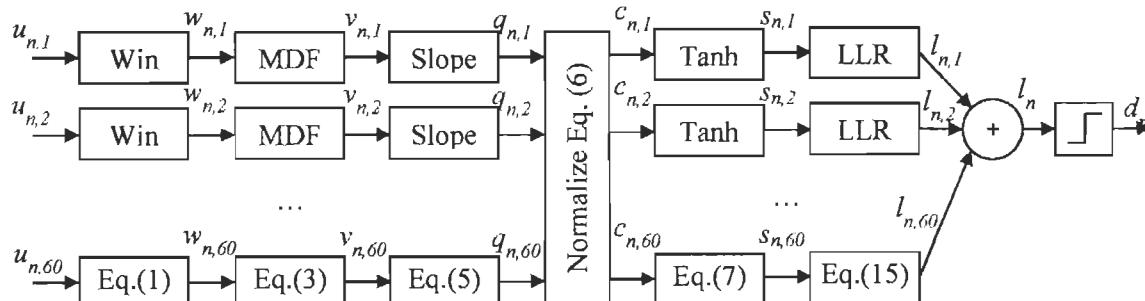


Fig. 1 Block-Diagram representation of the signal characteristics extraction and the naïve Bayesian classifier. This is the analysis system for the subject n . The abbreviations Win, MDF and LLR stand for Window function, Median Frequency and Log-Likelihood Ratio respectively.

Then, the slope $a_{n,m}$ is normalized by the intercept $b_{n,m}$:

$$q_{n,m} = a_{n,m}/b_{n,m} \quad (5)$$

The obtained value $q_{n,m}$ represents well the local muscular fatigue of a subject. However, this relation between the fatigue and the MDF relative slope is very variable between different subjects. Therefore, it is preferable to normalise $q_{n,m}$ within each subject:

$$c_{n,m} = \frac{q_{n,m}}{\sqrt{\sum_{m'=1}^{60} q_{n,m'}^2}} \quad (6)$$

The values $c_{n,m}$, $n \in \{1, \dots, 60\}$ are the spatial distribution of the MDF slope, a new metric presented in this article. Since the data contains often outliers or extreme values, their impact are reduced by the use of a soft saturation, the hyperbolic tangent:

$$s_{n,m} = \tanh\left(\frac{1}{3} c_{n,m}\right) \quad (7)$$

The signal is scaled in order to reduce mainly the value that stands above 3 standard deviations.

C) Calculation of the log likelihood ratio

The log likelihood ratio is defined by:

$$l_{n,m} = \ln\left(\frac{P(LBP|s_{n,m})P(LBP)}{P(CTRL|s_{n,m})P(CTRL)}\right) \quad (8)$$

where LBP and CTRL are labels for the LBP and control class, respectively. Since the number of subjects is limited, a parametric method for evaluating the probabilities is preferred. The parametric methods that are used necessitate the estimation of the mean and the variance:

$$\bar{s}_{m,C} = \frac{1}{N_C} \sum_{n \in C} s_{n,m} \quad (9)$$

$$\hat{\sigma}_{m,C}^2 = \frac{1}{N_C - 1} \sum_{n \in C} (s_{n,m}^2 - \bar{s}_{m,C}^2) \quad (10)$$

C is the class (LBP or CTRL) and N_C is the number of subjects in the class C . The normal distribution is the most commonly used distribution to construct the likelihood function:

$$P(C|s_{n,m}) = \frac{1}{\hat{\sigma}_{m,C}\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{s_{n,m}-\bar{s}_{m,C}}{\hat{\sigma}_{m,C}}\right)^2} \quad (11)$$

The log likelihood ratio with this distribution is:

$$\begin{aligned} l_{n,m} = & \frac{1}{2} \left(\left(\frac{s_{n,m} - \bar{s}_{m,CTRL}}{\hat{\sigma}_{m,CTRL}} \right)^2 - \left(\frac{s_{n,m} - \bar{s}_{m,LBP}}{\hat{\sigma}_{m,LBP}} \right)^2 \right) \\ & + \ln \left(\frac{\hat{\sigma}_{m,CTRL}}{\hat{\sigma}_{m,LBP}} \right) + \ln \left(\frac{P(LBP)}{1 - P(LBP)} \right) \end{aligned} \quad (12)$$

It is a general formula which is often simplified when the standard deviations are identical. In the case here, the standard deviations are different and the usual simplifications cannot be applied.

The *a priori* probability $P(LBP)$ is considered unknown, i.e. $P(LBP) = P(CTRL) = 0.5$. Hence, the LLR based on the Gaussian distribution is:

$$\begin{aligned} l_{n,m} = & \frac{1}{2} \left(\left(\frac{s_{n,m} - \bar{s}_{m,CTRL}}{\hat{\sigma}_{m,CTRL}} \right)^2 - \left(\frac{s_{n,m} - \bar{s}_{m,LBP}}{\hat{\sigma}_{m,LBP}} \right)^2 \right) \\ & + \ln \left(\frac{\hat{\sigma}_{m,CTRL}}{\hat{\sigma}_{m,LBP}} \right) \end{aligned} \quad (13)$$

It should be mentioned that the last term in (12) may be adjusted to apply a bias to the classifier in order to trade-off between sensitivity and sensibility.

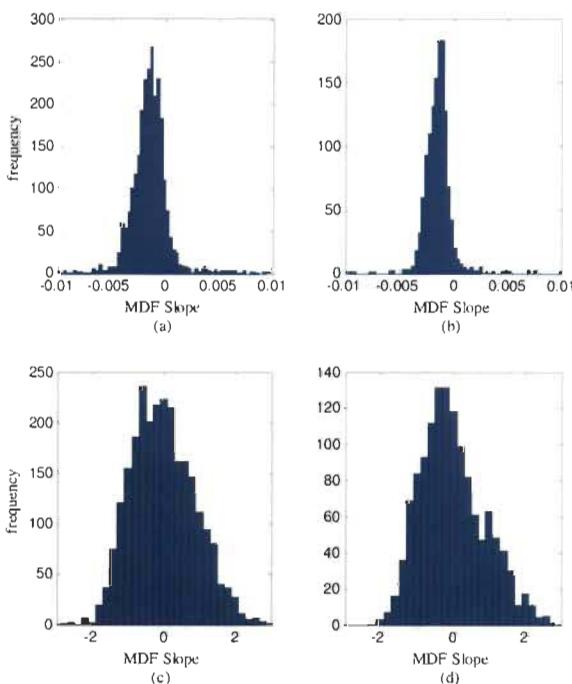


Fig. 2 Histogram of the MDF of all sensors before signal conditioning for the left matrix (a) and the right matrix (b) and after signal conditioning for the left matrix (c) and the right matrix (d).

Because the number of subject is limited, specifically for the control group, the variance is not very well known. The Student distribution can be used to take this aspect into account. The Student distribution is based on the T -statistic which is calculated for each sensor for each class C :

$$T_{n,m,C} = \frac{s_{n,m} - \bar{s}_{m,C}}{\hat{\sigma}_{m,C}} \quad (14)$$

This statistic is used for obtaining the probability density from the Student distribution, written $f_T(T_{n,m,LBP})$. The log likelihood ratio using the Student distribution is then:

$$l_{n,m} = \ln \left(\frac{f_T(T_{n,m,LBP})}{f_T(T_{n,m,CTRL})} \right) + \ln \left(\frac{P(LBP)}{1 - P(LBP)} \right) \quad (15)$$

D) Naïve Bayesian Classifier

Although the sensors signals are correlated, this aspect is neglected in the Naïve Bayes Classification. Hence, whether the log likelihood is formed by the Normal or the Student's distribution, the combining of the LLRs is done by simple summation:

$$l_n = \sum_{m=1}^{60} l_{n,m} \quad (16)$$

Finally, the sign of the total LLR l_n is the decision rule for classification:

$$d_n = \begin{cases} LBP & \text{if } l_n > 0 \\ CTRL & \text{if } l_n \leq 0 \end{cases} \quad (17)$$

E) Note on Power-line and Electrocardiogram Interference

The sEMG signals are often affected by power line interference (PLI) and electrocardiogram interference (ECG). Many techniques exist to remove these interferences. However, it is generally preferable to reduce to the minimal the distortion of EMG signal. Hence, filtering should be avoided as much as possible [16]. Moreover, the fact that it is the slopes of the MDF that is used for classification makes the method intrinsically robust to PLI and ECG interference. For the PLI, a constant signal at 50 or 60Hz will affect only slightly the normalized MDF slope. In the same way, the ECG spectrum is relatively statistically constant. Although, it can vary over time due to heart acceleration, the trend of acceleration should be more or less similar for each subject and has little impact on the ECG power spectrum. Also, the ECG is harder to remove than the PLI because its frequency band is much larger. For those reasons, in this paper, no particular filtering has been applied for PLI and ECG.

3. ANALYSIS METHODS

This section describes the methods used to analyse the proposed method. The misclassification rate (MCR), a performance measure is discussed. Then, cross-validation

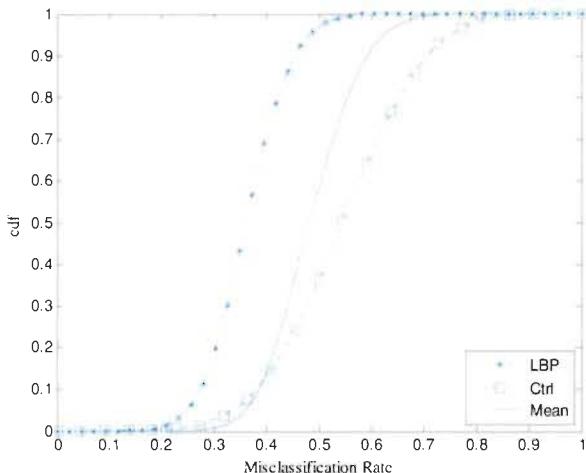


Fig. 3 Empirical cdf for the left matrix of the null hypothesis that the obtained MCR are due to random variations. These pdfs have been generated by 20000 random permutations of the classes. For each permutation, a complete cycle of leave-one out cross validation is done. The curve of the mean MCR is the CDF of the average of the MCR of the LBP and control group. The graphics obtained for the right matrix are very similar.

method is presented. After, the attention is drawn to the hypothesis testing method.

A) Performance Measure

The performances of the Naïve Bayesian Classifier for the LBP classification are based on the misclassification rate. In this two class classification problem, there are two types of misclassification. Hence, a misclassification rate is given for both classes. The misclassification rate associated with LBP refers to the probability that a LBP subject will be classified as a non LBP subject (or control subject). The same logic goes for the misclassification rate of the control group.

B) Cross-Validation Method

The performances of an algorithm can sometime be studied on the training group, from which the parameters are adjusted. Obviously, the performances estimated from a training group are generally better than on data outside the training group. Although in some situations this effect can be neglected, in the case of high dimensionality systems and low number of subjects as in the present case, the difference can become very high. However, since the number of test subjects is relatively low in comparison to the number of variables, taking a large part of the data to form a test group is impracticable. For this reason, a leave-one-out cross validation method is preferred. The mean misclassification error rate is calculated by averaging in the MCR of the two groups.

C) Statistical Significance of the MCR

Since the number of subject is limited and the MCR are relatively high, it is important to assess the statistical significance of the misclassification error rate. This can be done by a permutation test. A Monte-Carlo simulation is used to test the null hypothesis that the classes (LBP or

Control) do not explain the obtained MCRs. At every Monte-Carlo iteration the classes are randomly assigned by selecting randomly 22 subjects to be part of the LBP group and 43 to the Control group, the classifier is trained, a full cycle of cross-validation is completed and a MCR is calculated for the 2 groups. After many iterations of Monte-Carlo simulation, the probability density functions (PDFs) of the MCRs are computed for the LBP group, the control group and the mean of the groups. The MCRs for the mean of the groups is calculated by averaging the mean of the groups. Then, the p-values are extracted based on a one-sided integration of the PDFs. Hence, the p-values match the cumulative distribution functions (CDFs). It must be noted that the MCRs of the 2 groups are strongly correlated. For this reason, the joint CDF of the MRCs of the 2 groups is also calculated. The joint CDF is built from the joint PDF as follow:

$$F_{X,Y}(x,y) = P_{X,Y}(X < x, Y < y) \quad (18)$$

Also, the correlation between the MCRs of each group under null hypothesis is taken into account by this approach. It should be emphasized that a p-value extracted from this relation should not be compared to the p-values of the univariate CDF.

4. EXPERIMENTAL RESULTS

The results for the extraction of the characteristics, the permutation tests and classification are presented in this section.

The histograms in Fig.2 show the distribution of the spatial distribution of the MDF slope of all the sensors for all subjects for the right and the left matrices, before ($q_{n,m}$) and after ($s_{n,m}$) the normalization and the soft saturation. It is reasonable to consider the signals after conditioning as normally distributed.

The Fig.3 shows the MCR's experimental CDF for the LBP group, for the control group and the mean of the two

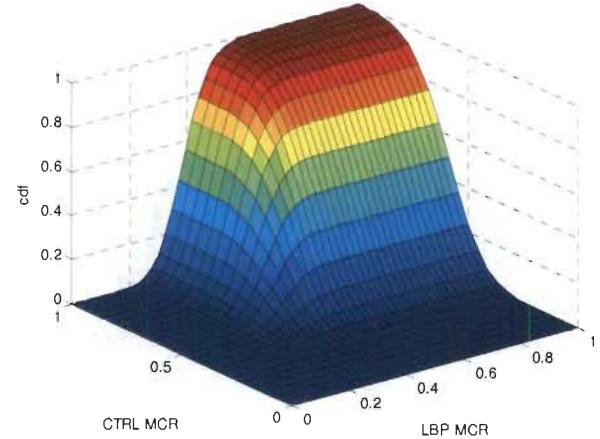


Fig. 4 Joint CDF of the MCR under null hypothesis of the left matrix. The figure has been generated by 20000 permutations.

groups for the sensor matrix of the left side. These distributions are based on the permutation tests with 20000 trials. It should be noted that there is a large difference between the CDFs of the MCR of the two groups under null hypothesis. Also, the curve of the mean value goes below the two other curves. This means that the MCR of the two groups are correlated.

Fig.4 shows the joint CDF for the matrix sensor of the left side. Also, a correlation between the MCR of the two groups of 0.39 has been found for the left matrix and 0.42 for the right matrix.

Table 1 presents the performances of the algorithm. The results are shown for the training group and with the leave-one-out cross-validation method. The p-value is associated with the MCR of the validation group. In Table 2, the p-values of the joint cumulative distribution functions are presented. No important differences were noted between the Gaussian and Student distributions based LLRs. The results for the Gaussian distribution are presented.

The most important aspect of the results presented in this paper is that it is representative of the results that would be obtained on new data. The principal reason is that only minor parameters had to be chosen, namely the size of the windowing operation and the factor for the soft saturation. Moreover, these parameters where set before the training of the classifier. The Naïve Bayesian Classification method does not need additional parameters as for other learning machines such as Neural Networks, Support Vector Machine with soft margins, or even the simple k-nearest neighbours (the parameter being k). These methods generally need a validation and a test groups. Thus, a single leave-one-out cross validation is insufficient. Although a second level of cross-validation would be possible, the different parameters would have to be adjusted each time. This can be cumbersome.

A success rate of almost 70% of success (MCR of 31%) has been obtained. Although the results are not particularly impressive in term of MCR, it is the first significant results of classification of LBP subjects based on muscular fatigue reported with a rigorous cross-validation method. Also, we expect that the fact that the method is based on the Sorensen task, which targets only the low-back muscles, will improve the specificity of the test with regards to other musculoskeletal conditions. Clinically, this test could be used with other LBP tests that are more performant, but which are based on tasks that are less specific in term of targeting the lower-back region. Also, it can be said from that the MDF slope is an important source of information regarding the LBP classification problem and could be joined with other discriminants in order to obtain better classifiers and increase our understanding of LBP.

It can be viewed that without cross-validation, success rate of 80% can be attained. Although it is better than for the validation results, the interesting aspect is that it is not by much. For learning machine that uses regulation, the algorithm is well adjusted when the training and validation

Table 1 Performance of the proposed algorithm on training data (no cross-validation), with validation (leave-one-out method) and p-values of the MCR with validation.

	MCR (%) Train Data	MCR (%) Validation	p-Value
LBP Left	26	35	0,43
Control Left	14	27	0,013
Mean Left	20	31	0,0093
LBP Right	28	33	0,30
Control Right	18	36	0,08
Mean Right	23	34	0,0345

Table 2 P-values based on the joint CDF of the proposed algorithm with statistics calculated on the validation group (with leave-one-out cross-validation method)

	Left Matrix	Righ Matrix
Joint Distribution p-Value	0,0023	0,0148

results are similar. The Naïve Bayesian Classifier has given this without having any parameter to adjust.

The different p-values obtained suggest that the obtained MCR where not simply due to chance. The p-value of the mean MCR is the clearest result since it is low for both matrices and is based on a single variable distribution. The joint distribution p-values are the lowest values obtained, but are not based on single variable distribution and hence is less intuitive to interpret.

In two class problem, an MCR of 50% is generally the expected result of the null hypothesis. However, it was shown by that the Naïve Bayesian Classifier trained with different group size has a bias toward the group which has the higher number of subject since the CDF of the LBP group. This effect is NOT due to *a priori* probabilities but rather by the fact that the variance is better estimated in the case of the largest group. The *a priori* probabilities not considered in this article.

The distributions of MCRs obtained by the class permutations are conservative in the sense that if there is a difference between the groups, it cannot be totally cancelled by the class permutation because of the different size of the groups. The real p-values should be even lower than those obtained.

5. CONCLUSION

In this paper, we have outlined the advantage of the Naïve Bayesian classification with regards to the small datasets, specifically the fact that no parameter has to be chosen and the inherent robustness of the methods. Also, the utility of the matrices of sensor and the presented characteristic, the spatial distribution of the MDF slope, were found useful for classification purpose. A success rate of almost 70% was found with a proper cross-validation method and the statistical significance of this value was verified.

ACKNOWLEDGEMENT

The authors wish to thank the National Sciences and Engineering Research Council of Canada (NSERC), Fonds de recherche du Québec - Nature et technologies (FRQNT) and the Regroupement Stratégique en Micro-Systèmes du Québec (ReSMiQ) for financial support.

REFERENCES

- [1] K. Lalanne, D. Lafond, M. Descarreaux, "Modulation of the flexion-relaxation response by spinal manipulative therapy: a control group study," *Journal of manipulative and physiological therapeutics*, vol. 32, no 3, pp. 203-209, 2009.
- [2] S. I. Reger, A. Shah, T. C. Adams, J. Endredi, V. Ranganathan, G. H. Yue, M. T. Finneran, "Classification of large array surface myoelectric potentials from subjects with and without low back pain," *Journal of Electromyography and Kinesiology*, 16(4), pp. 392-401, 2006
- [3] W. Dankaerts, P.O'Sullivan, A. Burnett, L.Straker, P. Davey, R. Gupta, "Discriminating healthy controls and two clinical subgroups of nonspecific chronic low back pain patients using trunk muscle activation and lumbosacral kinematics of postures and movements: a statistical classification model," *Spine*, 34(15), pp. 1610-1618, 2009
- [4] F. Nougarou, D. Massicotte, M. Descarreaux, "Detection Method of Flexion-Relaxation Phenomenon Based on Wavelets for Patients with Low Back Pain," *EURASIP J. on Advances in Signal Processing*, pp. 1-17, July 2012.
- [5] B. Bigland-Ritchie, E. F. Donovan, C. S. Roussos, "Conduction velocity and EMG power spectrum changes in fatigue of sustained maximal effort," *J. Appl. Physiol.* 51, pp. 1300-1305, 1981.
- [6] N. A. Dimitrova, G. V. Dimitrov, "Interpretation of EMG changes with fatigue: facts, pitfalls, and fallacies," *Journal of Electromyography and Kinesiology*, vol. 13, no 1, pp. 13-36, 2003.
- [7] B. Elfving, G. Németh, I. Arvidsson et al., "Reliability of EMG spectral parameters in repeated measurements of back muscle fatigue," *Journal of Electromyography and Kinesiology*, vol. 9, no 4, pp. 235-243, 1999.
- [8] D. Farina, M. Gazzoni, R. Merletti, "Assessment of low back muscle fatigue by surface EMG signal analysis: methodological aspects," *Journal of Electromyography and Kinesiology*, vol. 13, no 4, pp. 319-332, 2003.
- [9] P. Coorevits, L. Danneels, D. Cambier et al., "Test-retest reliability of wavelet-and Fourier based EMG (instantaneous) median frequencies in the evaluation of back and hip muscle fatigue during isometric back extensions," *Journal of electromyography and kinesiology*, vol. 18, no 5, pp. 798-806, 2008.
- [10] C. Lariviere, A. B. Arsenault, D. Gravel et al., "Evaluation of measurement strategies to increase the reliability of EMG indices to assess back muscle fatigue and recovery," *Journal of Electromyography and Kinesiology*, vol. 12, no 2, pp. 91-102, 2002.
- [11] S. H. Roy, C. J. De Luca, J. Carlo, L. Snyder-Mackler et al., "Fatigue, recovery, and low back pain in varsity rowers," *Med Sci Sports Exerc*, vol. 22, no 4, pp. 463-9, 1990.
- [12] S. H. Roy, C. J. De Luca, J. Carlo, D. A. Casavant, "Lumbar muscle fatigue and chronic lower back pain," *Spine*, vol. 14, no 9, pp. 992-1001, 1989.
- [13] J. H. Friedman, "On bias, variance, 0/1—loss, and the curse-of-dimensionality," *Data mining and knowledge discovery*, vol. 1, no 1, pp. 55-77, 1997.
- [14] X. Wu, V. Kumar, J. R. Quinlan, et al., "Top 10 algorithms in data mining," *Knowledge and Information Systems*, vol. 14, no 1, pp. 1-37, 2008.
- [15] T. ITO, O. SHIRADO, H. SUZUKI, et al., "Lumbar trunk muscle endurance testing: an inexpensive alternative to a machine for evaluation," *Archives of physical medicine and rehabilitation*, vol. 77, no 1, pp. 75-79, 1996
- [16] M.B.I. Reaz, M.S. Hussain, and F. Mohd-Yasin, "Techniques of EMG Signal Analysis: Detection, Processing, Classification and Applications," *Biological Procedures Online*, vol. 8, no. 1, pp. 11-35, Mars 2006.

SURROGATE ANALYSIS OF FRACTAL DIMENSIONS FROM SEMG SENSOR ARRAY AS A PREDICTOR OF CHRONIC LOW BACK PAIN

Manouane Caza-Szoka, Daniel Massicotte, François Nougarou, Martin Descarreaux

Université du Québec à Trois-Rivières, Electrical and Computer Engineering Department

C.P. 500, Trois-Rivières, Québec, Canada, G9A 5H7, www.uqtr.ca/lssi

{manouane.caza-szoka, daniel.massicotte, nougarou, martin.descarreaux}@uqtr.ca

Abstract— In this paper, a method based on nonlinear analysis of sEMG sensor array signals (2 arrays of 5×13 sensors) to detect chronic low back pain is presented. The use of an FFT based surrogate analysis method isolates the nonlinear structure of the signals from the effect of the power spectrum. The fractal dimension is used for the nonlinear characteristic. From the sensor arrays, a certain number of channels which exhibits the most nonlinearity for a subject are kept as input of a small neural network. A leave-one-out type cross-validation method shows a success rate of 80%.

Keywords— Fractal, Surrogate, Features extraction, sEMG sensors, chronic LBP

1. INTRODUCTION

The chronic Low-Back Pain (cLBP) is the most common musculoskeletal problem [1] and still far from being understood. Being able to detect cLBP is an important step in increasing knowledge of this condition. Among other methods, the use of surface electromyography sensors (sEMG) has been studied for static tasks with some significant results with linear methods [2], but without being able to perform classification. The use of sEMG sensor arrays has given better results with static tasks, still with linear analysis [3][4]. Nonlinear analysis of the sEMG signals have not been used to detect cLBP. However, the more general subject of muscular fatigue has been studied by nonlinear methods [5]. It is therefore relevant to try this approach for the cLBP detection problem.

Nonlinear analysis is interested in structures in time series that do not come from linear stochastic systems such as low-dimension chaotic behaviour or fractal characteristic. One of the problems with nonlinear analysis methods is the effect of autocorrelation which generally dominates [5]. Fractal dimension is no exception. In fact, a low-pass signal will produce a much lower fractal dimension than a white noise. Although this aspect might be used for classification purpose, linear signal characteristics already highlight this aspect. These have been studied thoroughly and applied to the cLBP classification problem in the literature. The goal here is to find new sources of information, in order to enhance the understanding of cLBP. Hence, it is desirable to extract only the information about nonlinearity. The surrogate analysis allows this [6]. But, the surrogate analysis has not been used for a classification problem yet. Even in papers that seek to compare different groups, the surrogate analysis is only used to show the presence of non-linearity [7]. In this paper, we propose to use the results of the surrogate analysis as a

characteristic that is useful for detection of cLBP. To validate our method, we applied on experimental data a leave-one-out type cross-validation method.

The paper is organized as follows: the system and procedure are presented in Section 2 while the presentation of the analysis and classification methods is postponed in Section 3. The experimental results are reported in Section 4 and discuss in Section 5. Finally, Section 6 draws some brief conclusions.

2. EXPERIMENTAL PROCEDURE

In the experimentation presented in Fig.1 and realized in GRAN laboratory (chiropractic department, University of Quebec at Trois-Rivières, Qc, CA), two sEMG sensor arrays (5×13 sensors for each array, 12.5mm IED, OT Biolettronica, Italy) are applied on the *lumbar erector spinae* in order to study its neuromuscular strategy during an endurance task [10]. After being asked to perform a maximum voluntary isometric contraction, a Sorensen task with 30% of maximum force load is done until complete fatigue, with a visual feedback on a screen visible by the subject. Two groups of 12 subjects, one with cLBP condition

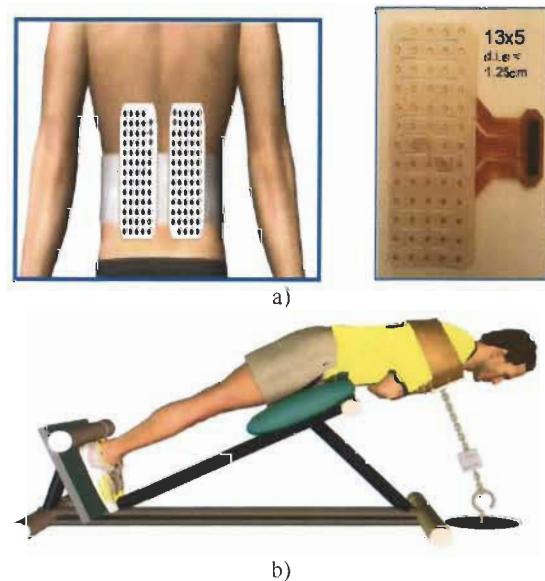


Fig. 1 Description of the realized experimentation a) representation of two (right and left) 64-electrode matrices used in the recording of erector spinae muscle activity (model ELSCH064; LISIN-OT Biolettronica, Torino, Italy) and b) illustration of a modified version of the Sorensen endurance test involving the use of a load cell and the feedback monitor.

and the other healthy were selected as detailed in [10]. Specifically, the healthy participants had absence of musculoskeletal or neurological symptoms related to a spine condition and other major injuries or conditions like arthritis or vascular problems. The subjects were considered to have chronic LBP condition if they had at least 50% of the last 6 months. Recurrent LBP, with episodes of symptoms over 12 months were included in the study. The cLBP patients were selected to be free from other conditions which could interfere with the study and would not be on non-steroidal anti-inflammatory drugs or analgesics on the day of experiment. The participants were asked to complete questionnaires prior the experiment, including the modified Oswestry Low Back Pain Disability Questionnaire, the Tampa Scale of Kinesiophobia, the Start Back Screening Tool and the Questionnaire Joint Hypermobility.

3. PROPOSED SIGNAL PROCESSING METHOD

The signal processing method to detect cLBP proposed can be summarized in the following steps:

- 1) A notch filter for powerline interference is applied,
- 2) A 10 seconds window of the data taken near the beginning is used,
- 3) A surrogate analysis method (Fig. 2) gives a score for each channel based on the fractal dimension,
- 4) The scores are sorted for each array and a certain number of extreme values are taken as signal characteristics (Fig. 3) to represent the feature extraction parameters,
- 5) The classification is done by an Artificial Neural Network (ANN) (Fig. 4).

The cross-validation is based on a leave-one-out type to obtain the performance results. Since the groups are small, a subject of each group was removed for every step of the leave-one-out to avoid imbalance of the group sizes during the training. Also, every combination (144) of subject removal was done in order to obtain a better resolution.

A) Fractal Dimension by Katz's method

The Katz's method to get an estimate of the fractal dimension is a popular method, very straightforward and easy to compute [9]. For 2 dimensional waveforms, where dimensions are homogeneous, it is obtained by:

$$D_K = \log(L_w)/\log(d) \quad (1)$$

with the total length L_w of the curve and d , the longest distance to the first data point. However, in the analysis of a time series, the units are inhomogeneous and a scaling parameter α must be included in the distance calculations:

$$L_w = \sum_n \sqrt{(u_{n+1} - u_n)^2 + \alpha^2} \quad (2)$$

$$d = \max\left(\sqrt{(u_n - u_1)^2 + \alpha^2(n-1)^2}\right) \quad (3)$$

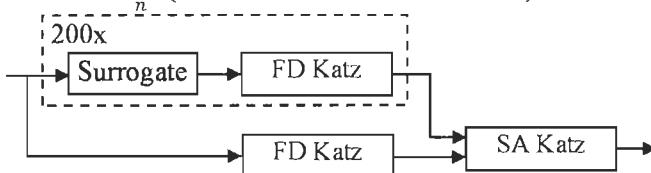


Fig. 2 The calculation of the Z score is done by comparing the fractal dimension of the original series to the distribution of the fractal dimensions obtained from the surrogate data. Here, SA stands for Surrogate Analysis.

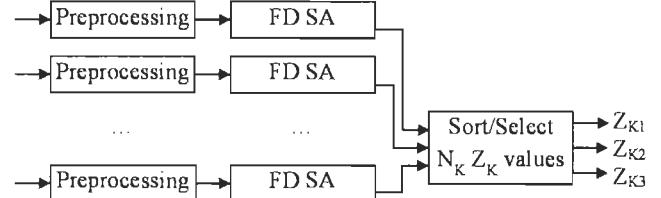


Fig. 3 The preprocessing, the surrogate analysis based on the Fractal Dimension and the sorting of the scores. Here, only the three scores with the minimum values are retained. The signals of both arrays have the same treatment.

where u_n is the sample signal at the sample n . A value of α which extract the richest information would be desirable. If α is close to zero, D_K reduces simply to a scaled version of the length of the curve. If α is high, D_K is almost not affected by the data. The choice of $\alpha = 0.05$ has been made by graphical observation, without any information on its effect on classification.

B) Surrogate Analysis

The surrogate analysis method is usually used in order to detect nonlinearity in signals [6]. We used Fast Fourier Transform (FFT) based method, which consists of randomizing the phase while keeping the original amplitudes in Fourier domain. A certain number (200 for each sensor in this paper) of surrogate series are obtained and the FDs are calculated. The FD of the original data is compared to the distribution of the surrogate FDs. The distance from the mean in term of standard deviations is the Z score:

$$Z = \frac{D - \bar{D}_S}{\text{std}(D_S)} \quad (4)$$

where D is the fractal dimension of the original time series and D_S is the fractal dimension of the surrogate series.

C) Z scores ordering and selection

The problem of high dimensionality of the data is often addressed by linear techniques of dimensionality reduction such as principal component analysis (PCA) or independent component analysis (ICA). However, PCA tends to destroy nonlinearity while ICA possibly gives too much importance of very weak signals. Hence, we propose to simply make a selection of the most nonlinear values obtained for each subjects.

D) Classification Method

A Feed Forward ANN with only five neurons in the hidden layer and a sigmoid output function was used, as presented in

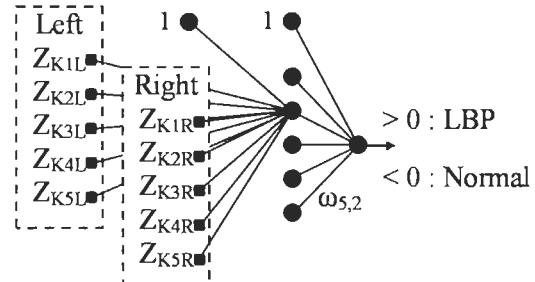


Fig. 4 The signal characteristics Z_K are used with a fully connected feed forward ANN. The left and right sensor arrays give their own sets of characteristics. For clarity, the connections from the inputs are only shown for one hidden layer neuron. The figure presents the case where 5 scores are taken.

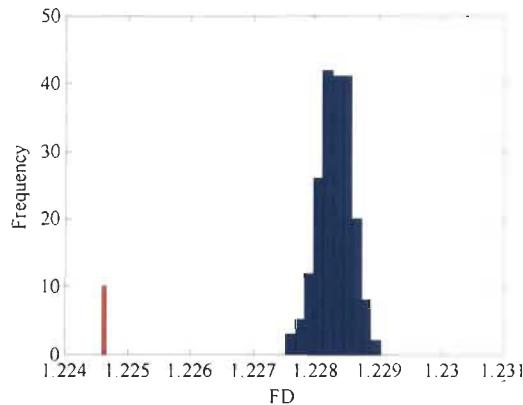


Fig. 5 Histogram of the FDs for the original data and the surrogate data. The frequency of the original data has been scaled by 10 for better visualisation.

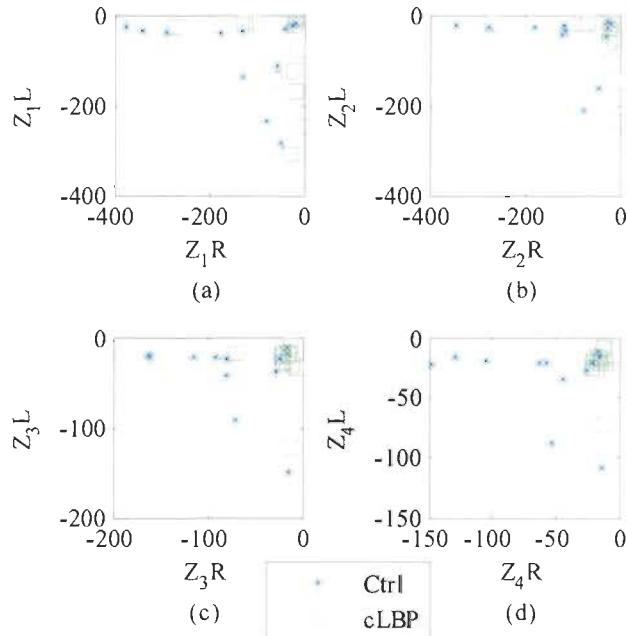


Fig. 6 Scatter plots of the first 4 Z scores, with the Z scores of the right sensor array in abscissa and Z scores of the left in ordinate. The indices of the axis labels are the rank of the scores.

Fig. 4. The optimization technique used was the Broyden, Fletcher, Goldfarb, and Shanno (BFGS) algorithm, with regulation to control generalization, with a criterion (MSEREG) weighting the mean square error (MSE) and mean square weight (MSW):

$$MSEREG = \gamma MSE + (1 - \gamma) MSW \quad (5)$$

The effect of the regulation parameter γ is different according to the number of inputs and neurones. The choice of γ is made empirically by comparing the training and cross-validation results. The number of iterations for adaptation was always 70 epochs.

4. EXPERIMENTAL RESULTS

The histogram in Fig. 5 shows the 200 FDs of the surrogate data of a single channel and the FD of the original data. The Z score that obtained from this channel was -14. Most of the extreme values were strongly negative. Hence, we only were interested in the strongly negative values.

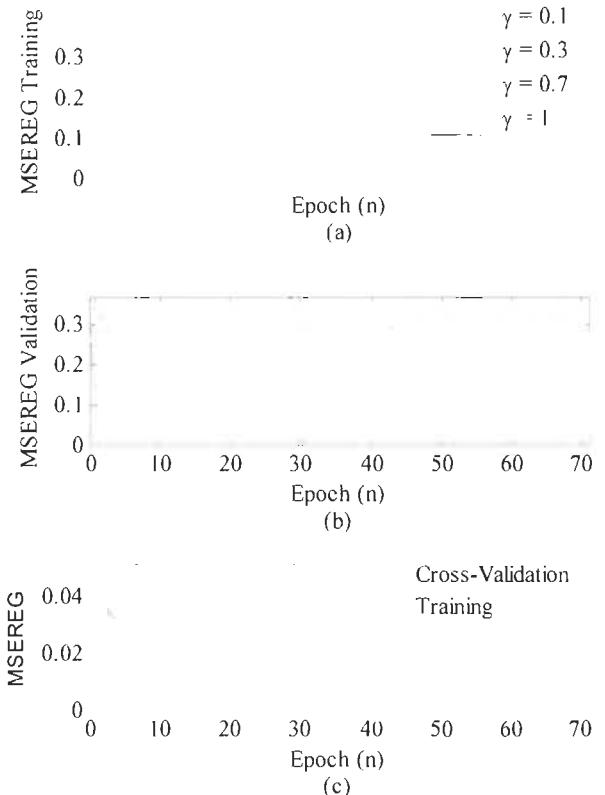


Fig. 7 Learning curves of the training (a) and validation (b) for different regulation factor, with 8 Z scores per array. The performances are shown in terms of MSEREG, not to be confused with MSE. An important aspect of the curves shown is the similarity between training and validation for strong regulation, i.e. $\gamma = 0.1$. For this value, the learning curves of training and validation are compared in (c).

The Fig. 6 shows the scatter plots of some Z scores in a left versus right sensor array relationship. The Fig. 6a presents the most negative score of every subject. We can observe that the scores of the control subjects tend to be more negative than for cLBP subjects. This aspect is more pronounced for the following ranks shown in Fig. 6b, c and d. We observed this effect for higher ranks as well. Remarkably, a left right imbalance in the control subject score can be found for high rank scores.

The learning curves of the Neural Network training and validation are shown in Fig. 7. From these curves we can choose a regulation factor γ which is reasonable without affecting the validity of the results by selecting it not by the best performance but rather on the similarity results between training and validation.

The success rates with cross-validation for the classification of the subjects are shown in Fig. 8a and the training performances are shown in Fig. 8b. The graphics present the success rate as a function of the number of Z scores used per sensor array. The different curves have different regulation factor, one being no regulation. We can see that in the case where the number of scores is low and the regulation factor is close to 0, the success rate is 0.5. This is due to the fact that the weights of the ANN become null. By comparing the results of the training and validation results, it can be seen that with the regulation factor of 0.1 the success rates are

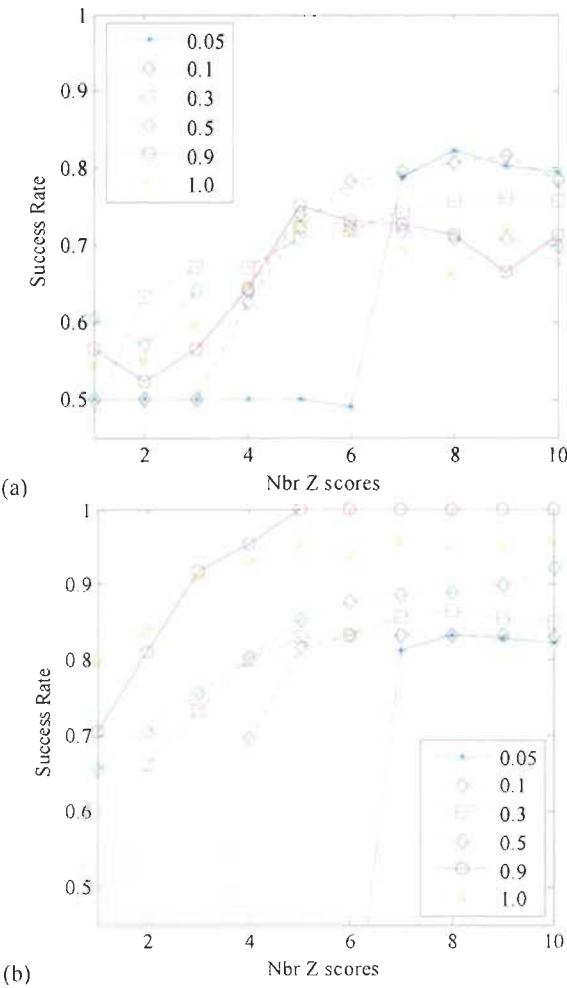


Fig. 8 Comparison of the success rate as a function of the number of Z scores. Cross-validation results are shown in (a) and the training performances are presented in (b).

similar for 8 scores. Also, the results are not very sensitive to the number of scores (the curves are flats) and to the regulation parameter (the curves with regulation factor of 0.05 and 0.3 give similar results). Hence, the success rate obtained of 80% is not taken from a singular point.

5. DISCUSSION

The most important aspect of the results presented in this paper is that the extracted nonlinearity quantity (the Z score) contains information that can be used to classify, and eventually understand cLBP. However, the Z score does not only represent the nonlinearity of the signal. It may be strongly influenced by the non-stationarity. Also, particularly for the sEMG, the signal is composed of motor unit action potentials (MUAPs) which are not white noise. If there are in large quantity and unsynchronized [10], it will by the law of large number give a Gaussian noise with the spectrum of the average MUAPs. However, if there is only a few activated MUAPs, or if they are fired coherently, the colored noise hypothesis is not valid. It would be interesting to be able to quantify separately nonlinearity, non-stationarity and synchronization. But for the moment, the Z scores is a characteristic that is affected by these three phenomena. We only used the term nonlinear throughout this paper for sake

of simplicity. It should be pointed out that the difference between the original and its surrogate data does not always indicate fractal structure caused by deterministic chaos, even for stationary process. One possible reason would be non-Gaussian stochastic behavior of the observed time series. To confirm this point, further systematic analysis is required. The idea of taking the extreme values is inspired from the ICA approach which states that the more non-Gaussian signals are more “interesting”. We suppose that the channels with the most nonlinearity are the most interesting. Also, we had a conceptual problem with the fact that large sensor arrays, with fixed sizes, are applied to subjects of different shapes. The ranked characteristics approach can be interpreted as follows: is it easier to find nonlinear signals on some subjects. The answer we found is that it is easier to find nonlinear signals in subject without LBP. We also think that this approach give better invariance regarding the shape of the subjects.

6. CONCLUSION

The two main things proposed in this paper were: (i) the use of surrogate analysis as a predictor, and (ii) the selection of some channels based on the ranking of the scores. We have shown that nonlinear analysis can be used for cLBP detection. The results obtained are clearly not caused by some particular choices, but rather robust to variations of the selected parameter such as regulation factor and number of chosen characteristics. Obviously, the signal characteristic should be combined to other characteristics and tested on larger groups. The method, or at least the framework, could be used for many other classification problems involving biosignals.

REFERENCES

- [1] K. Lalanne, D. Lafond, M. Descarreaux, “Modulation of the flexion-relaxation response by spinal manipulative therapy: a control group study,” Journal of manipulative and physiological therapeutics, vol. 32, no 3, pp. 203-209, 2009.
- [2] C. Lariviere, A. B. Arsenault, D. Gravel et al., “Evaluation of measurement strategies to increase the reliability of EMG indices to assess back muscle fatigue and recovery,” Journal of Electromyography and Kinesiology, vol. 12, no 2, 2002, pp. 91-102.
- [3] M. Caza-Szoka, D. Massicotte, F. Nougarou, “Naive Bayesian learning for small training samples: Application on chronic Low Back Pain diagnostic with sEMG sensors,” In Instrumentation and Measurement Technology Conference (I2MTC), Pise, April 2015, pp. 470-475.
- [4] S. J. Reger, V. Sahgal, “Analysis of large array surface myoelectric potentials for the low back muscles,” 23rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society, Vol. 2, pp. 1135-1138, 2001.
- [5] M. González-Izal, A. Malanda, E. Gorostiaga, M. Izquierdo, “Electromyographic models to assess muscle fatigue,” Journal of Electromyography and Kinesiology, vol. 22, no 4, pp. 501-512, 2012.
- [6] J. Theiler, S. Eubank, A. Longtin, B. Galdrikian, J. D. Farmer, “Testing for nonlinearity in time series: the method of surrogate data,” Physica D: Nonlinear Phenomena, 58(1-4), 77-94, 1992.
- [7] M. Lei, Wang, Z. Feng, “Detecting nonlinearity of action surface EMG signal,” Physics Letters, 290(5), pp. 297-303, 2001.
- [8] J. Abboud, F. Nougarou, I. Pagé, V. Cantin, D. Massicotte, M. Descarreaux, “Trunk motor variability in patients with non-specific chronic low back pain,” J. of Clinical Neurophysiology, Elsevier, pp. 1-10, Feb. 2014.
- [9] M. J. Katz, “Fractals and the analysis of waveforms,” Computers in biology and medicine, 18(3), pp. 145-156, 1988.
- [10] J. Sun, X. Hong, S. Tong, “Phase synchronization analysis of EEG signals: an evaluation based on surrogate tests,” IEEE Trans. on Biomedical Engineering, 59(8), pp. 2254-2263, 2012.

BEAMFORMING FOR POWERLINE INTERFERENCE IN LARGE SENSOR ARRAYS

Manouane Caza-Szoka, Daniel Massicotte, François Nougariou

Université du Québec à Trois-Rivières, Electrical and Computer Engineering Department

C.P. 500, Trois-Rivières, Québec, Canada, G9A 5H7, www.uqtr.ca/lssi

{manouane.caza-szoka, daniel.massicotte, nougarou}@uqtr.ca

Abstract – This paper shows how to use beamforming to remove the power-line interference (PLI) in large surface electromyography (sEMG) sensor array or high-density sEMG. The method exploits the highly correlated nature of the different sources of interference, being part of the same electrical grid, and their narrow frequency bands. The idea is to use a very narrow pass-band filter around 50 or 60 Hz to get signals with high PLI content before applying a spatial filtering by principal component analysis (PCA). This way, beamforming are done on the frequency bands where PLI are presents. Also, it ensures that even if the PLI has a smaller overall power than the desired signal, it will be easily found as the most powerful component of the decomposition. The PLI can then be removed from the signal. With trivial modification, harmonics of the PLI can also be removed. The approach was used in the context of muscle behavior analyses of low back pain patients using a sEMG array of 64 sensors. The performances of the filter are studied by experimental and semi-empirical methods. Compared to the usual notch filter, an improvement of up 10 dB is found.

Index Terms— *sEMG, PLI, PCA, Spatio-Frequency Filtering, Large Sensor Arrays, EMG, EEG, ECG*.

1. INTRODUCTION

Surface electromyography (sEMG), by detecting electrical potential generated by activated muscle cells, is an effective non-invasive method widely used in biomedical research. Time- and frequency-domain methods have been developed to analyze the sEMG response in order to give information about muscle contraction and muscle fatigue necessary to study neuromuscular human diseases and behaviors. However, sEMG signals and its extracted information are strongly contained by different kinds of noises and artifacts like power-line interferences (PLI), sEMG sensor movements or electrocardiogram (ECG) signals [1].

In this study, we focused on PLI in large sEMG arrays. The PLI 60 (50) Hz fundamental and its harmonics clearly corrupt the usable frequency bandwidth of sEMG signals in the range of 20 Hz to 450 Hz. Based on one sEMG sensor, common methods to reduce PLI consist to use frequency notch filters or to employ a reference sEMG as in [1]. For this kind of multivariate sEMG systems, the literature is very limited and the frequency notch filter is the prevalent simple solution. However, it is generally preferable to minimize the amount of filtering [5]. Contrary to the single channel case there is little research reported on the topic of removal of PLI in this context of large multichannel systems.

The PLI generally comes from a low number of well-correlated sources. In linear algebra terms, the PLI multivariate signal has a low dimensionality. In beamforming terms, it has a low spatial dimension. Also, the PLI has very narrow frequency bands for fundamental frequency and its harmonics. These characteristics of the PLI lead to think that the combination of spatial (beamforming) [2] and frequency filtering could be used to isolate it from the desired signal.

Beamforming principles have been explored in [3]-[6] for EEG systems. The beamforming method of principal component analysis (PCA) was used. PCA decomposes the signals by minimizing the correlation and order them by variance (i.e. power). In the case of EEG, the most powerful signals obtained after decomposition should contain the PLI. Independent component analysis (ICA) was necessary to further isolate the PLI among the results of the PCA. No similar approach has been done for sEMG systems. In the case of EEG, the PLI is generally much stronger than the desired signals. It is hence easier to isolate the PLI as being one of the strongest components. In the case of sEMG, the interference is generally of the same order of magnitude as the desired signal. The use PCA without prior filtering would lead to an ordering problem as in ICA.

A similar approach was used for ECG [7]-[11]. There, the signal power is stronger, but the number of sensors is very limited. Also, the ECG signal comes from a relatively localized source. It is therefore easier to use ICA to separate the ECG and PLI which are two well-defined sources. Even then, the ordering problem of ICA is still complex [9]. For sEMG signals, the desired signals come from a high number of sources (motor units) distributed over a larger region. This is particularly true for the low back region. The different motor units are more or less synchronized, but clearly less than the different components of the ECG. The ICA cannot easily be used with sEMG arrays.

For these reasons, we propose to apply a PCA based beamforming only in the frequency band of the PLI, without use of ICA. This approach is very straightforward, with few parameters and present many advantages:

- the method is not sensible to the choice of the parameters.
- the subspace selection is much easier than ICA based method since the PLI should be found by simple variance calculation. There is no major ordering problem.
- an error of subspace selection is of low impact since if the PLI is not the strongest signal in the PLI frequency band, than its impact is minor.

- In the large sensor array context, losing a few spatial dimensions of the desired signal in a narrow band has a negligible impact. Choosing the wrong subspace in ICA can lead to major error.

An analysis of the performances of the proposed method is done by adding a synthetic interference signal over real-world experimental data from our depicted experimentation on LBP patients at frequencies where the interference is generally not present. The performances are compared to a standard notch filter. The method of spatio-frequency filtering presented was designed for sEMG large sensor array applied on the low back region. The use of ICA was unnecessary to isolate the PLI. The approach should be readily adapted for EEG and ECG systems. The ICA could be incorporated to the method for those systems.

The paper is organized as follows; the proposed system is presented in Section 2. The analysis of the proposed filter is postponed to Section 3, while Section 4 draws some brief conclusions.

2. SPATIO-FREQUENCY NOTCH FILTER

The spatio-frequency notch filter proposed in Fig. 1 is used to cancel the signal in a limited frequency band in only one or few spatial directions. A spatial dimension is equivalent to a linear combination of measurement channels [2]. As an example, for 56 differential measurements matrix used, there are 56 spatial dimensions.

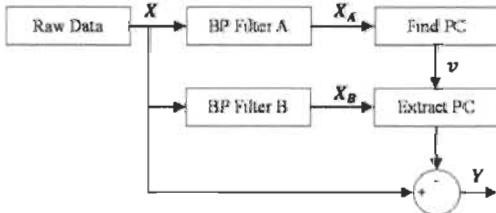


Fig. 1. Structures for the proposed spatio-frequency notch filter
In order to find the best spatial direction to be removed, the data is first passed through a narrow band-pass (BP) filter at the central frequency of the interference, the BP Filter A in Fig. 1. This ensures that the major part of the filtered signal is composed of interference, i.e. it minimizes the signal to interference ratio (SIR). After, on the filtered data, a search of the spatial direction (PC – principal component) where the signal is the strongest is done. PCA method is a common way of finding it. This direction is likely to contain most of the interference, especially if there is only one spatial source of interference. Then the raw data are filtered again with another band-pass filter of wider band, the BP Filter B. The part of the wideband filtered signal which is in the spatial direction found by PC extraction is subtracted from the raw data.

The algorithm can be applied for each undesired interference frequencies, such as harmonic frequencies. It can also be applied more than once at the same frequency when the interference has higher order of spatial dimensions.

A) Band-Pass Filtering

The Fast Fourier Transform (FFT) is used for the bandpass filters. The undesired frequencies are set to zero in the

frequency domain. The filtered signal is then returned in the time domain by applying the Inverse FFT (IFFT). This is reasonable for an offline data analysis. Also, since the time span of the data was large, windowing was unnecessary.

B) Principal Component

The PCA method first requires the estimation of the covariance matrix. It is the spatial correlation which is considered. The general equation for the covariance matrix for the system of Fig. 1 is:

$$\Sigma = E[(\mathbf{x}_A - E(\mathbf{x}_A))(\mathbf{x}_A - E(\mathbf{x}_A))^T] \quad (1)$$

where $E[\bullet]$ denotes the statistical expectation operator and \mathbf{x}_A is a $M \times 1$ vector related to the output of the BP Filter A with M the number of channels. However, because the signal was previously passed through an ideal band-pass filter, it has no mean. For the system of Fig. 1, under the assumption of stationarity, the estimator of Σ is:

$$\mathbf{Q} = \frac{1}{N} \mathbf{X}_A \mathbf{X}_A^T \quad (2)$$

where \mathbf{X}_A is a $M \times N$ matrix related to the output of the BP Filter A, with N for the number of data per channel and M the number of channels. The unbiased version of the estimated covariance matrix is used due that mean is null. An eigendecomposition of the estimated covariance matrix is:

$$\mathbf{Q} = \mathbf{V} \mathbf{D} \mathbf{V}^{-1} \quad (3)$$

The columns of the matrix \mathbf{V} are formed by the eigenvectors of \mathbf{Q} , ordered by the power of the eigenvalues found in \mathbf{D} . The first column vector of \mathbf{V} is written v and is the desired direction. The vector v is unitary.

C) Removal of the Spatio-Frequency Dimension

To remove the spatio-frequency dimension associated to the interference, the second band-pass filter, BP Filter B, is projected on the direction of the principal component v , and The data with interference removed \mathbf{Y} is also an $M \times N$ matrix

$$\mathbf{Y} = \mathbf{X} - v(v^T \mathbf{X}_B) \quad (4)$$

Here \mathbf{X} is the $M \times N$ matrix of the original raw data and \mathbf{X}_B is the matrix of the data filtered by the BP Filter B.

It could be possible to remove simultaneously many spatial dimensions. However, doing it in different steps allows changing the bandwidth of the filters for each spatial dimension. Let's note that the removal of principal components by reconstruction using remaining components, as usually done in PCA based denoising, would be more complex and less precise because most PC are kept.

3. EXPERIMENTAL RESULTS

In our case, we take advantage of a high number of sEMG sensors or high-density sEMG to remove PLI. Indeed, in our laboratory we applied an 8x8 sEMG array (Model ELSCH06NM3, 10 mm inter-electrode distance (IED), OT Bioelettronica, Italy), which gives 56 differential channels, on lumbar erector spinae muscles of a low back pain (LBP) patient [12]-[14] in order to study its neuromuscular strategy during an endurance task. In order to analyze the performances of the algorithm in a realistic context, two

scenarios are studied. In the Scenario 1, we applied the proposed method to real data from a typical large sEMG array signal to remove the data interferences. In the Scenario 2, a new simulated interference, known, has been added and the spatio-frequency notch filter is applied to remove the simulated interference in order to evaluate the performances.

A) Scenario 1: Real-World Noisy sEMG Grid Channels

The known interference is added in frequency regions where no interference was present in the original measured data. The proposed spatio-frequency notch filter is compared to the conventional frequency notch filter. There are 56 differential channels sampled at 2048 Hz. The Fig. 2 shows, as an example, the data from two EMG differential channels, in the time domain. The 56 channels are similar. Fig. 3(a) shows the frequency domain representation of the data (in absolute value). For clarity, the frequency axis is displayed up to 600 Hz instead of the 1024 Hz allowed by the sampling frequency. Interference spikes can be seen principally at 120 Hz and 300 Hz. Furthermore, other harmonics of 60 Hz are present. However, no dominant interference is found in the 60 Hz itself, a common situation when PLI is mostly produced by lighting equipment. Although the spikes are very narrow (either in the -3 dB or in 99% power bandwidth

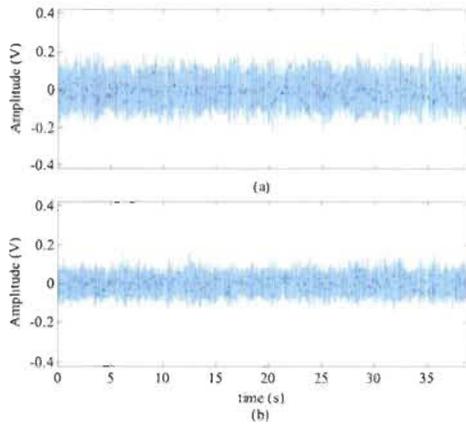


Fig. 2. Raw data in the time domain of two measurements of differential channels sampled at 2048 Hz.

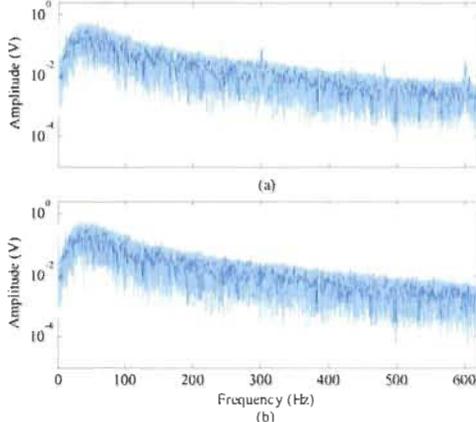


Fig. 3. Raw data (a) and data with interference removed by the proposed spatio-frequency notch of one measurement channel in the frequency domain (b).

sense), its impact on the signal has a significant bandwidth. Fig. 4 compares on experimental data in Fig. 4(a), the results of the spatio-frequency notch filter in Fig. 4(b) and by standard notch filter in Fig. 4(c). The standard notch filter completely loses the desired signal in the interference bandwidth. Moreover, it can be seen that the interference at 300 Hz has more power than the desired signal over about 6 Hz of bandwidth. The full bandwidth of the significant interference should be even larger.

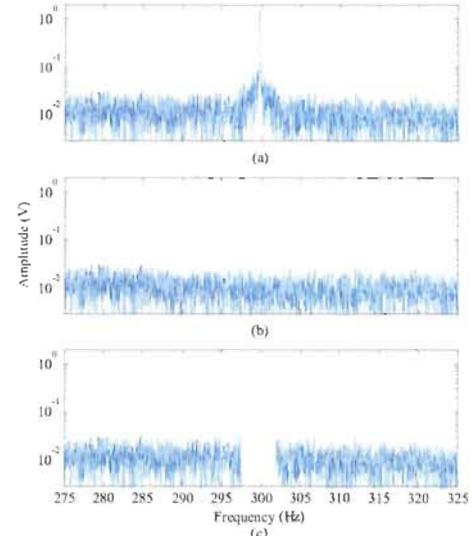


Fig. 4. Zoomed version around 300 Hz of Fig. 3a (a) and data with interference removed by the proposed spatio-frequency notch Fig. 3b (b) and by standard notch (c) of one measurement channel.

B) Scenario 2: Synthetic noisy sEMG grids

To evaluate the interference removing with the proposed and reference methods, an interference signal has been synthetically added to approximate typical real world interferences. The sine wave used had variable amplitude and phase. If PLI was a pure sinus signal, it would be very easy to remove it. The variations levels were chosen to make the simulated power spectrum similar to the experimental one (except for the central frequency).

The simulated interference frequency representation is shown in Fig. 5(a) for 110 Hz centered interference. Fig. 5(b) shows the sum of the data and simulated interference. The interference is produced in all of the 56 measurements with random scaling for amplitudes (Gaussian) and random phases (uniform). For the performance analysis, the mean square error (MSE) is considered. The MSE is normalized by the power of the interference. Hence, a normalized MSE of 0 dB means that the power of the error is equal to the power of the interference. Let's note that a positive MSE in dB can be interpreted as the desired signal that has been canceled more than the interference and is an undesired result.

In Fig. 6, the performances of the proposed spatio-frequency notch filter are compared to the performances of the conventional and usually used frequency notch filter. The bandwidth of the standard frequency notch filter is varied as

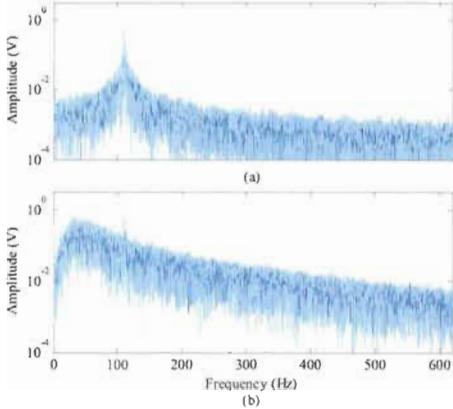


Fig. 5. Simulated interference (a) and data plus simulated interference (b) of one measurement channel. The interference has been created synthetically while the sEMG signals are experimental.

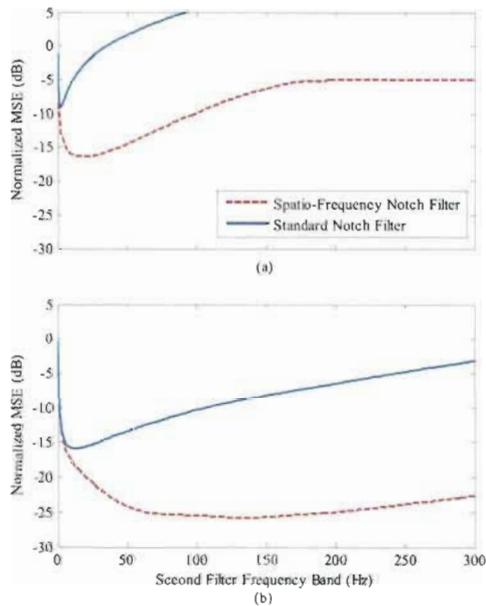


Fig. 6. Comparison between the proposed spatio-frequency notch filter (dashed line) and the standard notch filter (solid line) for interference suppression at 110 Hz (a) and 330 Hz (b).

the bandwidth of the BP Filter B of the spatio-frequency notch filter with 0.5 Hz for BP Filter A bandwidth. Two interference frequencies are considered, 110 and 330 Hz, the central frequencies are 110 Hz in Fig. 6(a) and 330 Hz in Fig. 6(b). In both cases, the spatio-frequency notch filter gives superior results than the standard frequency notch filter. At 110 Hz, the difference of MSE at the respective optimal frequency band is about 8 dB at 110 Hz and about 10 dB at 330 Hz. It can also be seen that the interferences are more easily removed at high frequency because the main power of the signal is at low frequency. Moreover, at low frequency, the performances are much more sensitive to the bandwidth. For instance, for the interference at 330 Hz, there is not a significant difference between the MSE found for a second filter frequency band between 50 Hz and 250 Hz.

Finally, the impact of the first filter frequency band (BP Filter A) is discussed. It is observed that for both 110 Hz

and 330 Hz interference, the best frequency band is the narrowest. However, a too narrow band needs a better knowledge of the center frequency of the interference.

4. CONCLUSION

In this paper, we have outlined an approach to isolate the PLI in a sensor array by exploiting the correlation of the interference between the channels and its narrow band frequency characteristic. This allows keeping most of the desired signal, even at the frequency of the PLI. The proposed technique has been shown to be effective on real data. Also, the performances were studied with simulated interference added to real data. We expect that the basic principles can be extended to EEG and ECG systems and to more general contexts, such as for dynamic task, where the subject (hence the sensors) is in movement. In this case, the beamforming and the filtering should be adaptive.

Acknowledgment – The authors wish to thank the Natural Sciences and Engineering Research Council of Canada and *Fonds Excellence UQTR* for their financial support.

REFERENCES

- [1] C. Kezi Selva Vijila, P. Kanagasabapathy, E. Selva Kumar, "A Survey of Interference Cancellation in Biosignals," Int. Journal of Reviews in Computing, vol.7, pp. 64-83, Sept. 2011.
- [2] B. D. Van Veen and K. M. Buckley, "Beamforming: a versatile approach to spatial filtering," in IEEE ASSP Magazine, vol. 5, no. 2, pp. 4-24, April 1988.
- [3] M.B.I. Reaz, M.S. Hussain, and F. Mohd-Yasin, "Techniques of EMG Signal Analysis: Detection, Processing, Classification and Applications," Biological Procedures Online, pp. 11-35, 2006.
- [4] S. Hu, M. Stead and G. A. Worrell, "Automatic Identification and Removal of Scalp Reference Signal for Intracranial EEGs Based on Independent Component Analysis," IEEE Trans. on Biomedical Engineering, vol.54, pp. 1560-1572, Sept. 2007.
- [5] S. Hu, M. Stead, G.A. Worrell, "Removal of Scalp Reference Signal and Line Noise for Intracranial EEGs," IEEE Int. Conf. on Networking, Sensing and Control, pp.1486-1491, April 2008.
- [6] C. Guerrero-Mosquera, A. Navia Vazquez, "Automatic removal of ocular artifacts from EEG data using adaptive filtering and independent component analysis", European Signal Processing Conference, pp. 2317-2321, Aug 2009.
- [7] A. S. Barhatte, R. Ghongade and S. V. Tekale, "Noise analysis of ECG signal using fast ICA," Conf. on Advances in Signal Processing, Pune, 2016, pp. 118-122.
- [8] W. Sanxiu and J. Shengtao, "Removal of Power Line Interference of ECG Signal Based on Independent Component Analysis," Int. Workshop on Education Technology and Computer Science, Wuhan, Hubei, 2009, pp. 328-330.
- [9] T. He, Clifford and L. Tarassenko "Application of ICA in Removing Artefacts from the ECG", Neural computing and Application, vol. 15 issue 2, April 2006
- [10] A. K. Barros, A. Mansour, and N. Ohnishi, "Removing artifacts from Electrocardiographic signals using independent components analysis," Neurocomputing, vol. 22, 1998.
- [11] M.P.S. Chawla "PCA & ICA Processing Methods For Removal Of Artifacts and Noise in ECG", Applied Soft Computing Journal Vol.11,2011
- [12] F. Nougarou, D. Massicotte, M. Descarreaux, "Detection Method of Flexion-Relaxation Phenomenon Based on Wavelets for Patients with Low Back Pain," EURASIP J. on Advances in Signal Processing, pp. 1-17, July 2012.
- [13] M. Caza-Szoka, D. Massicotte and F. Nougarou, "Naive Bayesian learning for small training samples: Application on chronic Low Back Pain diagnostic with sEMG sensors," 2015 IEEE Int. Instrumentation and Measurement Technology Conference (I2MTC) Proceedings, Pisa, 2015, pp. 470-475.
- [14] M. Caza-Szoka et al., "Surrogate analysis of fractal dimensions from SEMG sensor array as a predictor of chronic low back pain," Int. Conf. of the IEEE Engineering in Medicine and Biology Society (EMBC), Orlando, FL, 2016, pp. 6409-6412.

DETECTION OF NON RANDOM PHASE SIGNAL IN ADDITIVE NOISE WITH SURROGATE ANALYSIS

Manouane Caza-Szoka and Daniel Massicotte

Université du Québec à Trois-Rivières, Department of Electrical and Computer Engineering,
3351, Boul. des Forges, Trois-Rivières, Québec, Canada
Laboratoire des Signaux et Systèmes Intégrés
{manouane.caza-szoka, daniel.massicotte}@uqtr.ca

ABSTRACT

The Surrogate Analysis (SA) is known to detect nonlinear signals, non-stationary signals and ARMA systems driven by non-Gaussian processes. This paper adds to address the detection of non-random phase signal, of which the linear phase signal is the best-known example. This is a new interpretation of the SA. In order to highlights the benefits of the interpretation, a new theoretical signals is constructed. The signal has a perfect Gaussian distribution and is not affected by periodic extension and is a linear phase signal. The SA will be shown able to detect this signal in a noise with exactly the same power spectrum. It will be clear that the SA is able to detect phase linearity even when the data is normally distributed. An application of the detection by SA is given regarding very noisy and short time electrocardiogram (ECG) signal and compared to higher order statistics and normality tests for this purpose.

Index Terms— Nonlinear Analysis, Hypothesis Testing, Detection, Bootstrap Method, Biomedical Signal, Fractal Dimension.

I. INTRODUCTION

The Surrogate Analysis (SA) [1] is a widely used method of nonlinear analysis applied to a large spectrum of domain. The first applications were found in physics to detect low order chaos [2]. Since a large literature has been developed for the SA in the study of bio signals, notably in brain imaging techniques such as EEG and MEG [3][4]. Also, financial time series have been explored through SA [5].

The SA is a statistical test that has for null hypothesis that the signal can be obtained from a linearly filtered stationary white Gaussian noise (ARMA process). Any departure from this hypothesis yields a positive result [6]. Hence, although the assessment low order chaos was first aim of the SA, other underlying phenomena have been targeted. The effect of the time varying aspect has been noticed in [1][7], more as a bias of the SA. It was, however, later developed as a useful tool to assess non-stationarity in [8]. The non-Gaussian driving process deviation aspect has been considered in the context of financial time series [9]. It seems that the whole spectrum of possible departure from the null hypothesis has been treated. From another point of view, let is considered specifically the Fourier based SA [1], which is the original and most commonly used version of the SA. This approach

indirectly addresses the ARMA null hypothesis. More directly stated, the null hypothesis is that the signal is such as its phase in the Fourier Spectrum is random. From this hypothesis, a new possible departure from the null hypothesis is revealed. But there is a link between the two points of view. From the ARMA hypothesis, one could ask: “Can an ARMA system produce a signal in which there is a non-random Phase Spectrum?” A simple illustration of a non-randomness is the difference between a Dirac function and a white Gaussian noise: both have a constant power spectrum, but while the Dirac’s phase spectrum is linear, or even constant, the noise’s one is uniformly distributed. Obviously, it is usually not necessary to use nonlinear analysis to detect a Dirac signal.

This paper shows that the SA can detect some non-randomness in the phase spectrum of a signal. In the simplest form, this non-randomness will be a null or linear one. The demonstration is a new theoretical signal that has Gaussian distribution by construction, which is not affected by periodic extension and is a linear phase signal. A less theoretical simulation where a real electrocardiogram (ECG) signal is detected within a frame of approximately 2 seconds in high levels of noise will show that the method has potential practical applications. In that case, there is no question of linear phase signal but clearly, the ECG is not a random signal and its Phase Spectrum should neither be random. The Fractal Dimension (FD) will be used in the SA.

The detection of ECG signal is an important aspect in Fetal-ECG [10]. It is necessary for channel selection after application of Principal Component Analysis (PCA) and Independent Component Analysis (ICA). In [11], only the Kurtosis is used to perform the channel selection. This paper shows that the SA can be more sensitive for detecting the ECG component. Also, the proposed method could be used also in a preprocessing step prior to the PCA and ICA by selecting the “most interesting” channels. This is important since the position of the sensors of Fetal-ECG systems are not necessarily placed at constant locations in relation to the fetus and the number of sensors are generally high. Let’s note briefly that the ECG detection could in a similar way be useful in wearable ECG devices [12], especially when a good contact of the electrodes with the skin is not guaranteed. It must be emphasized that, the detection problem has never been tackled by the use of SA, e.g. [13][14]. The SA was only used to assess the signal characteristic in order to validate a

model or the validity of a nonlinear feature, with the exception of [15] where a SA scores were used as a signal feature for a classification problem.

The paper is organized as follows: Section 2 presents the SA and FD algorithms. Section 3 details the test signals and experimentations and performance results are discussed in Section 4. Finally, the conclusions are drawn in Section 5.

2. ALGORITHMS

The Surrogate Analysis (SA) and the Fractal Dimension (FD) methods are detailed in this section.

2.1. Surrogate Analysis

The SA is presented in its most standard version as in the Theiler's paper [1] and is shown in Fig. 1, where x defined the original data signal. It consists of comparing a nonlinear feature of the original series to the same features calculated on surrogate series. The surrogate series are generated by phase randomization in the Fourier domain, more precisely by sequentially applying the Fast Fourier Transform (FFT) to the original data to transform the data in the frequency domain, randomize the phase with conjugate symmetry to keep the signal real, and using the Inverse FFT (IFFT) to obtain the time domain surrogate.

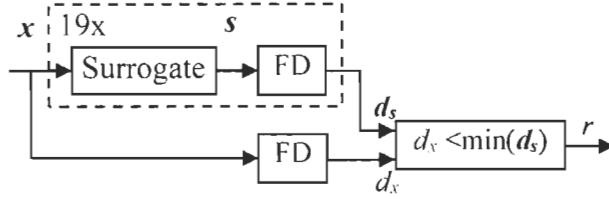


Fig. 1. Surrogate analysis for a left-sided unilateral test. Nineteen surrogate signals are generated. The FD of the original data x is compared to the minimum FD of the surrogates.

2.2. Fractal Dimensions

Two methods for calculating the FD are considered, namely the Higuchi's [16] and Katz's [17] methods. These come from slightly different theory and yield different results, especially when series are not pure fractals, which is almost always the case. Also, the methods have parameters which can highly modify their behavior [18][19]. It is desirable that the two methods show different aspects of the signals.

The Higuchi's method consists of the slope L Spectrum, i.e. the logarithm of the signal absolute length with respect to the logarithm of the subsampling factor k :

$$L_m(k) = \sum_{i=1}^{\frac{N}{k}-1} |x(ik+m) - x((i-1) \cdot k + m)| / k \quad (1)$$

This spectrum is averaged for m , the starting point:

$$L(k) = \sum_{m=1}^k L_m(k) / k \quad (2)$$

It is possible to only take some subsampling factor k . When the maximum of k is high, the values are generally

logarithmically spaced. On the other side, the Katz's FD, D_K , is obtained by:

$$D_K = \log(L) / \log(d) \quad (3)$$

where L is the total length of the time series:

$$L = \sum_n \sqrt{(u_{n+1} - u_n)^2 + \alpha^2} \quad (4)$$

and d is the maximum distance between any two points.

$$d = \sqrt{\max_n ((u_n - u_1)^2 + \alpha^2(n-1)^2)} \quad (5)$$

The signal at time step n is denoted by u_n . The parameter α is the homogeneity factor between the time and signal units. The method was made for waveforms, i.e. for multidimensional data where the dimensions are homogeneous. For time series, an appropriate ratio between the time step and signal units must be chosen [19]. However, by choosing this ratio high enough, it can be shown that the Katz's FD will correspond to a regularized version of the offset of the Higuchi's method L Spectrum, likely giving different information. Finally, to ensure that the Katz's method is amplitude scale invariant, a normalization of the signal is done before calculation of the FDs. Let's note that Higuchi's method is intrinsically amplitude scale invariant.

3. TEST SIGNALS AND NUMERICAL EXPERIMENTATION

Two experiments are proposed to highlights the detection capacity of the SA, one purely numerical and the other semi-empirical.

3.1. Perfectly Gaussian Impulse in Colored Noise

The goal of the first experiment is to detect a signal that has a perfectly Gaussian distribution and which is in noise which has exactly the same power spectrum. The signal is composed built around the Inverse Cumulative Distribution Function (ICDF) of the Gaussian distribution. If the ICDF was to be used as the final signal, it would be extremely easy to detect by the SA because of the discontinuity induced by the periodic extension of the FFT. Therefore, by using twice the ICDF in reverse order, the periodic extension discontinuity can be completely removed. To make the signal more similar to other common pulse, it is rearranged such that it starts and finished at zero. This is simply equivalent to applying a circular delay. It is noteworthy that the peak values are determined by the number of data points used in the ICDF. The additive noise is constructed to have the same power spectrum as the signal itself by using the same process as for the generation of the surrogate series. Such approach to create a colored noise was not found in the literature. The signal and an example of the noisy signal are shown in Fig. 2 (a) and (b).

The detection is considered unsupervised, meaning that no information about the signal will be used, apart the fact that it is not stochastic. The question asked by applying the detection algorithms is "Is there something that is non-stochastic?". Although the SA has never been used for a

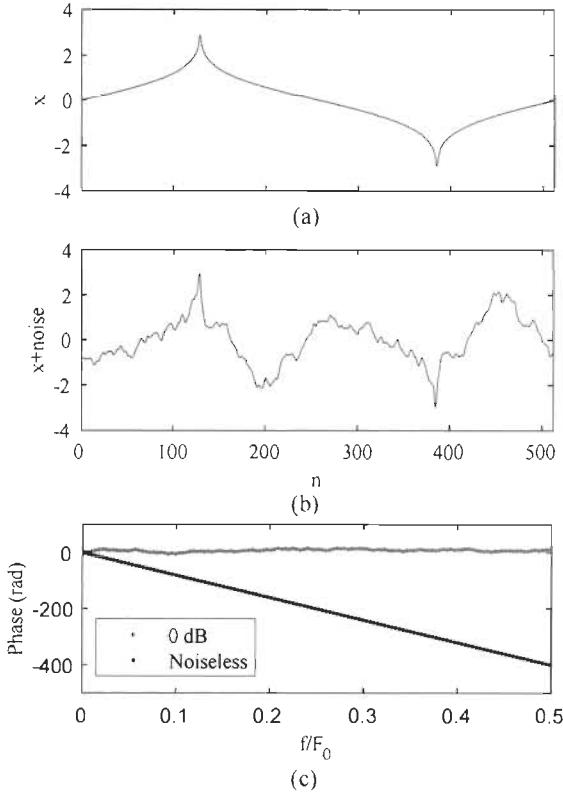


Fig. 2. Proposed signal with perfect normal distribution (a) and noisy version (b) at an SNR of 0 dB. The signal is created by the inverse cumulative function of the Normal distribution of 256 points, used twice, for a total of 512 points. The signal starts and finishes at 0. The added noise is done by phase randomization of the signal in the Fourier domain. It has the same power spectrum as the original signal. The unwrapped version of the phase spectrum is shown in (c) for the noiseless and noisy signal.

detection problem, SA is made to answer that last question. It will be compared with Kolmogorov-Smirnov (KS) [20] and Shapiro-Wilk (SW) [21] normality test which represents a good overview of the existing methods [22]. The KS and SW tests used $\alpha = 0.05$. The effect of both the signal to noise ratio (SNR) and the number of data points are observed. The Monte-Carlo simulation will have 10 000 trials per point.

3.2. Detection of ECG in Noise

To show the potential of the SA to be used for real-world applications, the detection of ECG within noise was done. A real ECG signal, from Physionet Databank [23] (first subject, fourth channel), is taken as the known, noiseless signal. Obviously, this signal contains noise, but it is of much lower power than the noise that is added synthetically. The additive noise is a random Gaussian white noise. The particular channel was chosen so that simpler detection methods such as thresholding would perform poorly. The time span of the windows was 2.048 seconds. It is a reasonably short period of time to detect presence of ECG for most thinkable applications. Although it is clear that any filtering method would increase the effective SNR drastically (easily over 7 dBs), the interaction between the filtering and nonlinear

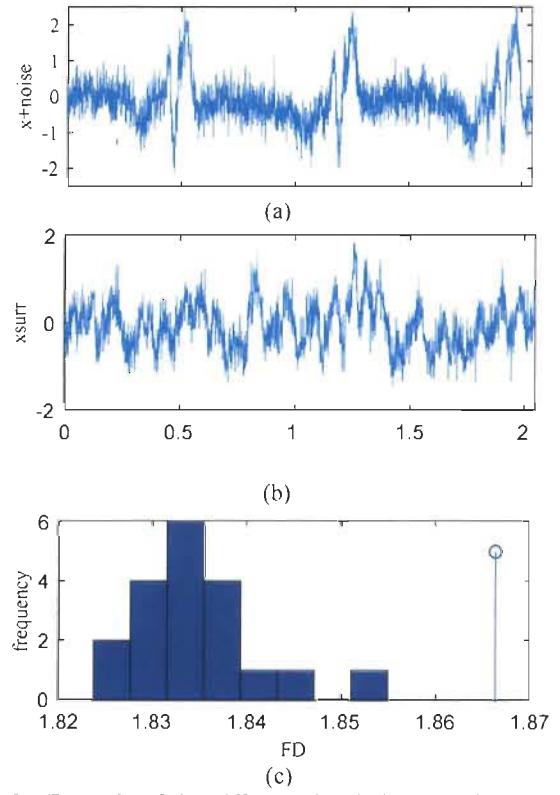


Fig. 3. Example of the different signals involved in the ECG detection experiment for a 2.048 second window and an SNR of 8 dB. In (a), the noisy ECG is shown. It is on the windowed version that the phase randomization is performed. An example of surrogate signal is shown in (b). It is on the windowed version that the FD is calculated. The distribution of the 19 surrogate series FDs is presented for Higuchi's method in (c) along with the FD of the noisy series located by the stem at FD = 1.866.

features is not well defined in the literature, and even less for SA. For this reason, the use of filtering is postponed for future works. In the case of windowing, it is shown in [24] that it can avoid spurious detections. Hence, a Tuckey window with a flat section ratio of 0.5 was used. Examples of the different signals involved in the ECG detection are shown in Fig. 3 (a) and (b). The windowed version of the signal is not shown. The Monte-Carlo simulation will have 30 000 trials per points, with windows selected randomly along the time series.

4. RESULTS AND DISCUSSION

The phase spectrum of the noiseless signal and the noisy version at 0 dB are presented in Fig. 2 (c). For the noiseless version, it is perfectly linear. With the noise, the non-randomness of the phase is unclear from the plot, but it was detected by the SA. Hence, the SA can detect non-random relation that is difficult to see from the phase spectrum. In Fig. 4, the detection rates for Higuchi's SA and SW test are shown. Quite surprisingly, in Fig. 4 (b) the SW test was giving positive results at low SNR. This means that even though the original signal is Gaussian, its Surrogate can become non-Gaussian. It is a fact, in our knowing, not found

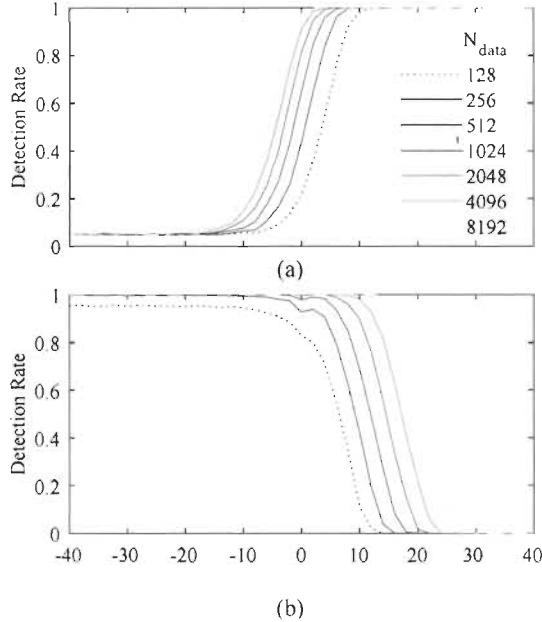


Fig. 4. Detection Rates of the normally distributed pulse in surrogate noise. The Higuchi (a) based SA method and SW (b) normality tests are shown.

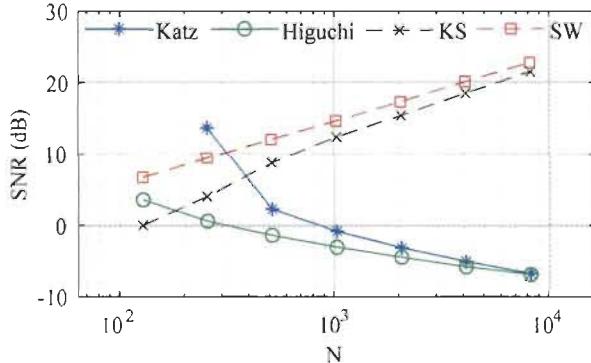


Fig. 5. SNR at 50% detection rate of the Normally Distributed Impulse according to the number of data points N for the four detection methods.

in the literature. Because of this reverse relation, the performances of the different algorithms were compared at a 50% detection rate in Fig. 5. While for the SA method, Katz and Higuchi, more data gives better results, it's the opposite for the KS and SW tests. Hence, the longer the data, the more its Surrogate has a Gaussian distribution.

Although both Katz's and Higuchi's are FD methods, they had fairly different performance in both experiments. This is not necessarily a negative point for Katz's method. It might indicate that the two methods detect uncorrelated aspects and in this case, it may be possible to use both methods together.

Because of the behaviour observed on the theoretical study, it was decided to adjust the method so that a 5% false positive rate would be obtained on pure noise for the ECG detection simulations. The noisy ECG and one surrogate example are given in Fig. 3 (a) and (b) while an example of Surrogate FD

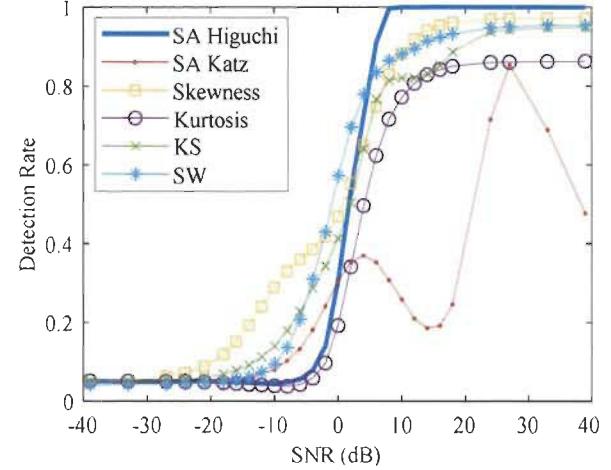


Fig. 6. Results for ECG detection in noise for SA, HOS and normality tests. The threshold were set so that there is a Detection Rate (misclassified) of 5%.

distribution is found in (c). The ECG detection results are shown in Fig. 6. No particular method was dominating the other. However, the Higuchi's SA had the sharpest transition and was the only one to obtain 100% success rate at high SNR. Again, it could be suggested to use multiple nonlinear features to obtain better results.

5. CONCLUSION

In this paper, a new interpretation of the SA, along with a signal with perfect normal distribution and linear phase was presented. This signal allowed to highlight the fact that SA is able to detect non ARMA signals even when the data is normally distributed. Moreover, the use of SA for the detection of ECG (or even any desired signal) in noise was shown for the first time. A theoretical simulation showed that the SA could outperform other nonlinear features that are based on the distribution. The interpretation of the theoretical results was that SA could detect phase linearity. To show the potential of the SA and its new interpretation on real-world applications, the detection of an ECG signal in noise was therefore tried by the method. It was shown that SA could again be used advantageously. Further research needs to be done to apply the filtering with SA and to combine the different nonlinear features in a single detector.

ACKNOWLEDGEMENTS

This work has been funded by the Natural Sciences and Engineering Research Council of Canada and the Research Chair in Signals and Intelligence of High Performance Systems.

REFERENCES

- [1] J. Theiler, S. Eubank, A. Longtin, B. Galdrikian, and J. D. Farmer, "Testing for nonlinearity in time series: the method of surrogates," *Physica D: Nonlinear Phenomena*, vol. 58, no. 1-4, pp. 77–94, 1992.

- [2] E. Bradley and H. Kantz, "Nonlinear time-series analysis revisited," *Chaos: An Interdisciplinary Journal of Nonlinear Science*, vol. 25, no. 9, p. 097610, 2015.
- [3] C. Stam, "Nonlinear dynamical analysis of EEG and MEG: Review of an emerging field," *Clinical Neurophysiology*, vol. 116, no. 10, pp. 2266–2301, 2005.
- [4] R. G. Andrzejak, K. Lehnertz, F. Mormann, C. Rieke, P. David, and C. E. Elger, "Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state," *Physical Review E*, vol. 64, no. 6, 2001.
- [5] S.-H. Chen, T. Lux, and M. Marchesi, "Testing for non-linear structure in an artificial financial market," *Journal of Economic Behavior & Organization*, vol. 46, no. 3, pp. 327–342, 2001.
- [6] J. Timmer, "What Can Be Inferred from Surrogate Data Testing?," *Physical Review Letters*, vol. 85, no. 12, pp. 2647–2647, 2000.
- [7] J. Theiler, "Spurious dimension from correlation algorithms applied to limited time-series data," *Physical Review A*, vol. 34, no. 3, pp. 2427–2432, Jan. 1986.
- [8] J. Timmer, "Power of surrogate data testing with respect to nonstationarity," *Physical Review E*, vol. 58, no. 4, pp. 5153–5156, Jan. 1998.
- [9] W. Zhou, "The components of empirical multifractality in financial returns", *EPL (Europhysics Letters)*, vol. 88, no. 2, p. 28004, 2009.
- [10] Martinek, R. Kahankova, J. Jezewski, R. Jaros, J. Mohylova, M. Fajkus, J. Nedoma, P. Janku and H. Nazeran, "Comparative Effectiveness of ICA and PCA in Extraction of Fetal ECG From Abdominal Signals: Toward Non-invasive Fetal Monitoring", *Frontiers in Physiology*, vol. 9, 2018.
- [11] R. Sameni, C. Jutten and M. B. Shamsollahi, "What ICA provides for ECG processing: Application to noninvasive fetal ECG extraction." In Proc. of the International Symposium on Signal Processing and Information Technology (ISSPIT'06), Vancouver, Canada, pp. 656-661., 2006.
- [12] N. Lokare, L. Gonzalez and E. Lobaton, "Comparing wearable devices with wet and textile electrodes for activity recognition," 2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), 2016.
- [13] R. Govindan, K. Narayanan and M. Gopinathan, "On the evidence of deterministic chaos in ECG: Surrogate and predictability analysis", *Chaos: An Interdisciplinary Journal of Nonlinear Science*, vol. 8, no. 2, pp. 495-502, 1998.
- [14] P. Tass, M. Rosenblum, J. Weule, J. Kurths, A. Pikovsky, J. Volkmann, A. Schnitzler and H. Freund, "Detection of Phase Locking from Noisy Data: Application to Magnetoencephalography", *Physical Review Letters*, vol. 81, no. 15, pp. 3291-3294, 1998.
- [15] M. Caza-Szoka, D. Massicotte, F. Nougarou, and M. Descarreaux, "Surrogate analysis of fractal dimensions from SEMG sensor array as a predictor of chronic low back pain," 2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), 2016.
- [16] T. Higuchi, "Approach to an irregular time series on the basis of the fractal theory," *Physica D: Nonlinear Phenomena*, vol. 31, no. 2, pp. 277–283, 1988.
- [17] M. J. Katz, "Fractals and the analysis of waveforms," *Computers in Biology and Medicine*, vol. 18, no. 3, pp. 145–156, 1988.
- [18] R. Esteller, G. Vachtsevanos, J. Echauz, and B. Litt, "A comparison of waveform fractal dimension algorithms," *IEEE Transactions on Circuits and Systems I: Fundamental Theory and Applications*, vol. 48, no. 2, pp. 177–183, 2001.
- [19] P. Castiglioni, "What is wrong in Katz's method? Comments on: 'A note on fractal dimensions of biomedical waveforms,'" *Computers in Biology and Medicine*, vol. 40, no. 11-12, pp. 950–952, 2010.
- [20] F. J. Massey, "The Kolmogorov-Smirnov Test for Goodness of Fit," *Journal of the American Statistical Association*, vol. 46, no. 253, pp. 68–78, 1951.
- [21] S. S. Shapiro and M. B. Wilk, "An analysis of variance test for normality (complete samples)," *Biometrika*, vol. 52, no. 3-4, pp. 591–611, Jan. 1965.
- [22] N. M. Razali and Y. B Wah, "Power comparisons of Shapiro-Wilk, Kolmogorov-Smirnov, Lilliefors and Anderson-Darling Tests." *Journal of statistical modeling and analytics*, vol. 2, no. 1, pp. 21-33, 2011.
- [23] Bousseljot, R.; Kreiseler, D.: Schnabel, A. Nutzung der EKG-Signaldatenbank CARDIODAT der PTB über das Internet. Biomedizinische Technik. Band 40. Ergänzungsband 1 (1995) S 317
- [24] T. Suzuki, T. Ikeguchi, and M. Suzuki, "Effects of data windows on the methods of surrogate data." *Physical Review E*, vol. 71, no. 5, 2005.

COMPLEMENTARITY OF KATZ'S AND HIGUCHI'S FRACTAL DIMENSION METHODS WITH APPLICATION IN SURROGATE ANALYSIS BASED LOW BACK PAIN DETECTION

Manouane Caza-Szoka, Daniel Massicotte, François Nougarou

Université du Québec à Trois-Rivières, Electrical and Computer Engineering Department
C.P. 500, Trois-Rivières, Québec, Canada, G9A 5H7, www.uqtr.ca/lssi
{manouane.caza-szoka, daniel.massicotte, nougarou}@uqtr.ca

ABSTRACT

This paper shows that the Katz's and Higuchi's methods can lead to complementary nonlinear information. A theoretical explanation of the relation between the fractal methods is first given. Because the interest is in the nonlinear aspect of the features, a continuous version of the Surrogate Analysis method is used to extract nonlinear information. To show that the nonlinear information between the two features is complementary, they are used to analyse three well known theoretical nonlinear time series. A situation where the FD methods taken independently cannot separate the three time series but taken together separation is possible is shown. Also, an application with real signals is given. The features are used for detection of chronic Low Back Pain subjects with a dataset comprising 24 subjects (two groups of 12). Very simple, Neural Networks are used as classifier. The performances are assessed by a leave-one-out type cross-validation method and sensitivity analysis of the meta-parameters. While previous works showed 80% success rate with Katz's method only and new results shows an 85% success rate with Higuchi's method only, the combining of the two methods raises the performances to over 90% success rate.

Index Terms— *sEMG, LBP, CLBP, Sensor Arrays*

1. INTRODUCTION

As Fractal Dimension (FD) was first imagined for approaching natural geometric shapes, many ways to calculate it were derived generally using the relation of some metric applied at multiple scales. However, a method that is pertinent for the present exposé makes use of a curve length measured at a single scale [1].

The idea of FD was rapidly transfer from the geometric analysis world to the domain of signal processing. Again, many ways to calculate the FD were derived, adapted for time series. Notably, Higuchi's method [2] which relied on the curve length taken at multiple scales while Katz's method [3] used a single scale, covering together the same approaches that were used in the geometric domain.

For Katz's method, much discussion have been made about its precision. But while it is not a method that give an unbiased FD [4], it has still been used successfully throughout the literature [4]. It is therefore justified to analyze this method with respect to its ability to extract useful information rather than to give a precise estimation of the FD. While every FD method has parameters, this paper highlights and exploits

the fact that Katz's method has a parameter that change drastically its behavior. It will be shown that there are three types of such behavior.

When FD methods were developed and analyzed they were generally evaluated with test signals of known theoretical FD. For example, in [5], Higuchi's FD method was tested on time series with specific power-law indexes. In [6], different fractal methods were tested on some tests signals showed large disparities between the calculated and theoretical FD. However, other than accuracy and consistency, an important approach to the FD method analysis was explored: the useful information extracted. It showed that while being less precise, some fractal methods were more useful than other to detect epileptic seizures. A similar kind of validation is used here. It is noteworthy that even if [6] analyzed the different method with respect to the extracted useful information, it did not took advantage of removing the precision requirement with respect to theoretical time series. In Katz's method, if the parameter is not selected such as to match a theoretical FD, it becomes a free parameter, possibly able to allow more extraction of useful information. Here, this freedom is not used to increase the information extracted from Katz's method, but rather to increase its complementarity to Higuchi's method. Hence, we show that the Katz's method can be complementary to Higuchi's method with a certain parameter choice. By complementarity, it is said with the common meaning "improving each other's quality" rather than the more mathematical ways were the sum of the two equals one.

The FD in used in signal processing with two main goal, one linear and one nonlinear. For the linear objective, the idea is to extract a feature that summarizes well the Power Spectrum. Conversely for the nonlinear point of view, the idea to use the FD is to extract information not already extractable from the Power Spectrum. It would not be interesting to find a difference between the fractal methods if it was an information obtainable from linear methods. The nonlinear features are generally influenced strongly by linear aspects, already explained by the power spectrum [6]. Hence, the nonlinear aspects must be extracted. To do this, the method of Surrogate Analysis (SA) is considered [7]. However, this common hypothesis test gives only a true/false results, making it difficult to be used as signal characteristic. A continuous version of the SA given in [8] is rather used. The extraction and complementarity of the nonlinear aspects of the FD methods are tested on theoretical time series. It is shown that it is possible with the SA to extract features that

are independent to the Median Frequency (MDF) of the time series. It is also shown that the features obtained from the two FD method can separate signals that cannot be separated by one method only.

To show that the complementarity between the FD methods has practical applications, the detection of chronic Low-Back-Pain (CLBP) [8] is performed. By comparing the detection success rate obtained, it is shown that better results are obtained by combining both fractal methods. The CLBP detection is an extremely frequent musculoskeletal condition [9]. Therefore, its easy detection is desirable. Linear methods have been studied for this purpose in [10], where the median frequency (MDF) slope of the Power Spectrum of Surface Electromyography sensors (SEMG) signals was shown statistically different between CLBP subjects and control, but with an effect size insufficient to perform reasonable classification performances. The classification of CLBP subject has been done in [11] by using large sensor arrays of SEMG with a success rate of 70%. With SEMG sensors, nonlinear methods have been mostly used in the study of muscular fatigue [12], the FD method being an important nonlinear approach to the subject. The use of Katz's method has given success rate of 80% for the CLBP detection problem with the use of large SEMG sensor arrays. The combination of FD methods presented here gives success rate of about 90%.

The main originality of this paper consists in showing that the FD methods can be used usefully together. It is expected that the presented findings could be applied to other applications where one FD method is already used, not only with SEMG sensors [13] but also from Electrocardiogram (ECG) [14] or Electroencephalogram (EEG) data [15].

The paper is organized as follows; the Katz's and Higuchi's FD estimation methods are recalled in Section 2. The relation between the FD methods is presented in Section 3. The SA method to extract nonlinear information is described along with numerical experimentation illustrating the complementarity of the FD method in Section 4. The experimental methodology and the classification algorithm are presented in Section 5. The experimental results are reported in Section 6. A discussion is found in Section 7. Finally, Section 8 draws some conclusions.

2. FRACTAL DIMENSION METHODS

In this section, the Higuchi's and Katz's methods are recalled with an emphasis for the free parameters, the implication on detection problems and its cross-validation.

A) Higuchi's method

The method to compute the fractal dimension D_H proposed by Higuchi [3] is well suited for time series analysis, because it does not come from the analysis of image. The idea is to

measure the length of the time series with different subsampling rate.

The length of a curve is defined by the sum of absolute difference between 2 consecutive points:

$$L = \sum_{i=1}^{N-1} |x(i+1) - x(i)| \quad (1)$$

When the subsampling is applied, the length of the curve includes a division by the subsampling factor k :

$$L_1(k) = \sum_{i=1}^{\frac{N}{k}-1} |x(ik+1) - x((i-1) \cdot k + 1)| / k \quad (2)$$

Moreover, when there is a subsampling of factor k , there are k possible starting points:

$$L_m(k) = \sum_{i=1}^{\frac{N}{k}-1} |x(ik+m) - x((i-1) \cdot k + m)| / k \quad (3)$$

Including the border effects, we get the equation (4). The results are averaged for m :

$$L(k) = \sum_{m=1}^k L_m(k) / k \quad (5)$$

The fractal dimension is the slope of $L(k)$ with respect to k after logarithmic transformation:

$$D_H = \frac{d\log(L(k))}{d\log(k)} \quad (6)$$

This slope is computed by linear regression in the linear region starting at $k = 1$ and ending at a parameter k_{max} . The linear region is not necessarily easy to determine in the case of real signals. The choice of the parameter k_{max} might be seen as arbitrary, particularly for classification purpose. This parameter could be optimized for better results. If large subsampling factors are used, it is better to use logarithmically spaced vectors. But for a smaller linear region, using all available information for the regression is a reasonable choice.

With many time series studied, it is easier to keep k_{max} constant. Selecting the linear region automatically could give unexpected behaviours, especially since the linear region is not usually perfect. Hence, a k_{max} of 5 has been chosen and applied for all signals.

$$L_m(k) = \left\{ \left(\sum_{i=1}^{\frac{N-m}{k}} |u(ik+m) - u((i-1)k + m)| \right) \frac{N-1}{[\frac{N-m}{k}] \cdot k} \right\} / k \quad (4)$$

B) Katz's method

The Katz's FD estimation dimension is a time series version of the estimation of the single scale method for geometric figures [1]. For the FD estimation of a line embedded in a plane, where dimensions are homogeneous (no time involved), it can be by the following:

$$D_K = \log(L_T)/\log(d) \quad (7)$$

The total length of the waveform L_T has must not be confused with L in the Higuchi's method. It is obtained by the following:

$$L_T = \text{sum}(\text{dist}(i, i + 1)) \quad (8)$$

The "dist" function is the distance between two consecutive points:

$$\text{dist}(i, i + 1) = \sqrt{(x_{i+1} - x_i)^2 + (y_{i+1} - y_i)^2} \quad (9)$$

and d is the maximum distance between any point and the origin:

$$d = \max_j(\text{dist}(1, j)). \quad (10)$$

For the time series case, the units are inhomogeneous. Often, it includes time and voltage. Hence, a scaling parameter β must be included, such as:

$$\text{dist}(i, i + 1) = \sqrt{((u_{n+1} - u_n)^2 + \beta^2(t_{n+1} - t_n)^2)} \quad (11)$$

Noting that $\Delta t = t_{n+1} - t_n$ is constant and setting $\alpha = \beta\Delta t$, we get:

$$\text{dist}(i, i + 1) = \sqrt{((u_{n+1} - u_n)^2 + \alpha^2)} \quad (12)$$

and:

$$d = \max_j \left(\sqrt{((u_j - u_1)^2 + \alpha^2(j - 1)^2)} \right) \quad (13)$$

The parameter α is generally made by using the mean absolute difference of u :

$$\alpha = \text{mean}(|u_{n+1} - u_n|). \quad (14)$$

However, in this paper, α is set independently of the signal. If α is not chosen according to this method, it becomes a free parameter that can be selected to extract information for detection or classification. Moreover, it can even be optimized for better performance.

3. RELATION BETWEEN KATZ'S AND HIGUCHI'S FRACTAL DIMENSION ESTIMATION METHODS

This section presents the relation between the length of the curve calculated by the Higuchi's method and the fractal dimension obtained by Katz's method for different values of α , first by theoretical description and second by a numerical example illustrating the concepts.

A) Theoretical explanation

Three situations that may occur depending of α are described here:

1) α is very small

In the case that α is negligible, the length of the waveform L_T reduces to the length as described for the Higuchi's method in eqn. (5) with no subsampling ($k = 1$). For d , it is slightly more complicated. One way of seeing the calculation of the fractal dimension with α small, or equal to 0, is to think to it as an ordered series of points embedded in a single dimension. It is suggested in [4] to use the difference between the maximum and minimum value of the data as a value of d . By letting α being very small, the same kind of effect is obtained. We obtain a value of d which is between half the maximum absolute value in the case where the first data is 0 and the near the difference between the maximum and minimum if the first value is close to an extreme value. In either case, there is a lack of robustness since using extremum values, but it could be easily fixed by taking more robust metrics such as the interdecile range.

2) The maximum distance to the origin is dominated by α

As α increases, it reaches a point where the maximum distance between any points to the origin becomes dominated by it. However, at this point the distance between two points is only slightly affected. In this case, we have the following conditions:

$$\alpha \ll \text{std}(u_{n+1} - u_n) \quad (15)$$

$$\alpha \gg \max_n(\text{abs}(u_n - u_1))/(N - 1) \quad (16)$$

where N is the number of points in the series. It is clear that if the number of data points N is high, the relationship of eqn. (15) will be attained before the one of eqn. (16). The value d becomes constant between different series of the same number of data points. The length of the curve L_T is almost unaffected. Hence, in this situation, the fractal dimension calculated can be interpreted simply as a scaled version of the length of the curve. This situation might not occur depending on the signal bandwidth and length.

3) α is of the order of magnitude similar to the signal

In the where the parameter α is significant in comparison to the signal, it is clear that again d can be considered as constant (unless in the presence of very small amount of data). However, the length of the curve L_T becomes strongly affected. With:

$$\Delta_u(i, i+1) = u_{n+1} - u_n \quad (17)$$

the sensitivity with regards to the signal is:

$$\frac{d}{d\Delta_u} \text{dist}(\Delta_u) = \frac{\Delta_u}{\sqrt{(\Delta_u)^2 + \alpha^2}} \quad (18)$$

This means that the calculated L_T will emphasize the large differences. It has a similar effect as calculating the length of the derivative of the curve.

B) Illustrative example

To give a clear numerical example showing the Brownian motion is used as in [5]:

$$X(n) = \sum_{n=0}^n x(n) \quad (19)$$

Since the Katz's method is used, the time series X is normalized to a zero mean and unit standard deviation. Let's note that the normalization has no effect on the Higuchi's method and that mean has no effect on Katz's method. A fairly long time series is used in order to let a clear region of α where the situation 2 arises. Therefore a time series of $n = 10000$ is used.

The results are shown in fig. 1. The time series used is shown in (a) and the Higuchi's curve lengths $L(k)$ is drawn in (b). The Katz's length L_T is shown in (c) in relation to α , along with the value of $L(I)$ from Higuchi's method. It is noteworthy that we have $L_T(0) = L(I)$. The relation of d with α is shown in (d) with asymptotic value ($N-1$) time α and the maximum absolute difference between any value. The three regions of the Katz's method are delimited in (c) and (d) and are determined graphically. The transition from the first to second region is found in the elbow of $d(\alpha)$ while the transition from the second to third region is obtained from the elbow of the curve length $L_I(\alpha)$.

4. SURROGATE ANALYSIS AND NONLINEAR COMPLEMENTARITY

Nonlinear analysis is interested in structures in time series that are not explained by the Power Spectrum. One of the problems with most nonlinear analysis method is the effect of autocorrelation which generally dominates [16]. FD is no exception. For example, a random low-pass signal will exhibit much lower fractal dimension than a white noise. Hence, to extract the nonlinear information from the FD, the SA [7] method is used.

In this section, the usual SA method used as hypothesis testing is first discussed. Then, the more recent continuous version of the SA is explained. A note on the effect of windowing is mentioned. Finally, an example of the SA can be used to show the complementarity between the two FD methods is given with the analysis of well-known theoretical nonlinear time series.

A) Discrete Surrogate analysis method

The SA method is usually used in order to assess nonlinearity in signals [7]. It is a hypothesis test with a null hypothesis which states that the signal is produced by a time invariant linearly filtered Gaussian noise. Signals that have the same autocorrelation (or power spectrum) than the original time series but respecting the null hypothesis are produced and their nonlinear characteristic are extracted.

In order to obtain such signals, the FFT based method of surrogate is used. Fig. 2 describes the process of creating a surrogate time series. It consists of applying the FFT to the original signal, randomizing the phase while keeping the original amplitudes and applying the IFFT. To get a real signal, the randomization must follow the constraint:

$$\phi(f) = \phi(-f) \quad (20)$$

A certain number of these surrogate time series are generated. Often, 19 time series are used for a one-sided test with a false rejection ratio of 0.05, although the true rate is generally higher due to diverse bias, such as windowing effects. The original series characteristic is compared with this distribution of the surrogate data nonlinear features. A one or two sided test can be chosen. However, it is often not possible to select which tail (left or right) should be chosen prior to the test. Hence, the two sided version is generally more reasonable.

When the signal is strongly nonlinear, the feature is often very far apart from the range of surrogate data features. This aspect is lost when hard decisions are done.

B) Continuous Surrogate Analysis method

In order to keep the "nonlinear information", a continuous version of the SA is used as was suggested in [8]. This version of the SA is similar to a p-value in a hypothesis test. It yields a score, calculated by the distance from the mean in standard deviation. Driven by a FD method, the Z score is obtained by:

$$Z = \frac{D - \bar{D}_S}{\text{std}(D_S)} \quad (21)$$

where D is the fractal dimension of the original time series and D_S is the fractal dimension of the surrogate series, from any method.

For this continuous case, the number of surrogate series is not determined by any threshold but by the precision needed. In this paper, 200 surrogate series are used. It is expected that the Z score highlight some aspect nonlinear information. The process of obtaining the Higuchi's and Katz's scores are shown in fig. 3.

C) Theoretical Nonlinear Time Series

In order to demonstrate the ability of the SA to separate the nonlinear aspect from the spectral features, three well-known nonlinear time series are analysed:

1) The Logistic map [17] is represented by a parabola with a single parameter r :

$$x[n+1] = rx[n](1 - x[n]) \quad (22)$$

Depending of the value of r , the time series can display chaotic behaviour. In this example, a value of 3.8 of r is selected.

2) The Henon map [18] is another common nonlinear map. It is generally written as a two dimension map but can be expressed as a single variable equation when only one dimensional time series is desired:

$$x[n+1] = 1 - ax[n]^2 + bx[n - 1] \quad (23)$$

The parameters selected in this paper are $a = 1.4$ and $b = 0.3$.

3) The Rössler system [19] can also give nonlinear time series:

$$\begin{aligned} dx/dt &= -y - z \\ dy/dt &= x + ay \\ dz/dt &= b + z(x - c) \end{aligned} \quad (24)$$

The parameters selected in this paper are $a = 0.2$, $b = 0.2$ and $c = 14$. The simulations was done with Runge-Kutta method of order 5 and a time step of 0.05s.

D) Surrogate Data to analyse the Surrogate Analysis method

To help analyze the ability of the SA to extract the nonlinear information, it is useful to compare linear and nonlinear time series with similar Power Spectrums. To obtain similar Power Spectrum the use of Surrogate Data series is appropriate. The Surrogate series is formed in the same manner as described earlier, with the FFT approach.

If a window method is used for the analysis of the nonlinear method, it should be used before the generation of the Surrogate Data to have identical Power Spectrums.

When the SA is applied on the Surrogate Series, applying again the windowing methods will allow to have the same operation made on the original and surrogate series. However, it will also affect the Power Spectrum.

The Surrogate Data does not have the sampling gap caused by the implicit periodic extension. It is hence less critical to use the second windowing step to reduce spurious effect of sampling gap. Hence, the SA of the Surrogate Data will not include windowing.

E) Effect of windowing methods

Windowing methods are sometimes used in the context of SA. They are particularly useful when the data length is short and the bandwidth is low [20]. The goal is to reduce the sampling gap caused by the implicit periodic extension when the FFT is used. Even though the windowing method enhances the Power Spectrum, it has the side effect of modifying the nonlinear features such as FD. Although a full analysis of this aspect is out of scope of this paper, it is

noteworthy that the window might in some case stabilize d in Katz's FD calculation. The windowing effect should reduce d towards the value $N\alpha$ where N is the data length.

F) Numerical experiment parameters

The three nonlinear time series presented along with their Surrogate Data are simulated for time series of length 256. Because the Rössler has a fairly low frequency content and the time series length is short, a Tukey window with a Taper Length of 0.05 [21] for every time series. The nonlinear time series are generated from random initial state and an initial transient time is discarded (100 for the Logistic map, 500 for the Henon map, 1000 for the Rössler system.) The surrogate series apply Fourier domain phase randomization of the windowed nonlinear time series. For each map and system, 5000 time series are generated. The SA uses 200 surrogate series for each time series. The data length is 256 samples unless specified otherwise.

G) Numerical experiment results

The results starts with histograms of the MDF nonlinear time series analysis and their surrogate series in fig. 4 (a). It is clear that while the MDF varies greatly between the different nonlinear time series, there is no significant difference with the MDF of the surrogate series. Hence, the linear method cannot detect the nonlinear features, as expected. It is noticeable that the MDF of the Rössler equation is extremely compact, in a single bin, except for some two other bins fairly separated (one is visible, the other is very week.) The Rössler equation with short time span can behave very differently from one sampling to the other.

The FDs are plotted with the Higuchi's method against the Katz's method. In fig. 4 (b), only the results for the surrogate series are shown. In fig. 4 (c), the emphasis is put on nonlinear time series results. Although there is a difference between the surrogate and nonlinear series, it is clear that the difference between the nonlinear series is principally driven by spectral aspects. It must be emphasise that the Katz's FD as used is not a good estimator of the theoretical FD. The parameter of the method is set to extract other aspect than Higuchi's method. For this reason, Katz's "FD" of values much higher than Higuchi's FD are found.

Similarly, the Z scores are plotted with the Higuchi's method against the Katz's method. In fig. 5 (a), again only the results for the surrogate series are shown. In fig. 5 (b), the emphasis is put on nonlinear time series results. This time, the results for the surrogate series are very similar even if the spectral features are very different and the difference between the Z scores of different nonlinear features are not driven by the spectral aspect, but rather by some kind of nonlinearity.

From the fig. 5 (b), the complementarity of the FD method is seen. A single method could not separate the three time series alone. However, using both method allows an easy separation of the series. Although the method do not separate completely the nonlinear series from the surrogate series, using longer data length helps the separation, as seen in fig. 5 (c) where series with data length of 1024 are used. The

larger spread of the scores for the surrogate series is due to windowing artifacts. In fig. 6, the data length is again 256 but no windowing method is used. The results are much fuzzier without the application of the window.

A last remark on the numerical result is that for a certain nonlinear time series, the correlation between the SA scores is only partially correlated. In fig. 5 (b), the correlation was 0.58 for the Logistic and Henon map but 0.02 for the Rössler system. A bootstrap method yields a maximum standard deviation of the correlations of 0.014. Hence, there is some complementarity found within a single nonlinear time series.

5. EXPERIMENTAL METHODOLOGY

In this section, the experimental procedure from [8] is recalled and the classification algorithm is adapted to receive SA scores from the two FD estimation methods.

A) Data set

The measurement is performed by 2 sensor arrays of 5x13 sEMG electrodes (12.5mm inter-electrode distance (IED), OT Biolettronica, Italy). The sensor arrays are placed on the *lumbar erector spinae* muscles in order to study its neuromuscular strategy during an endurance task. Two groups of 12 subject are studied, one with chronic Low Back Pain condition and a control group. The subjects performed a Sorensen task [22]. A 30% of maximal force load was asked to be maintained to the subject, with a visual feedback. The sampling frequency was 2048 Hz.

B) Signal Processing methods overview

The signal preprocessing and classification methods steps are:

- 1) Powerline Interference (PLI) removal by a notch filter
- 2) Selection of a 10 second window
- 3) SA scores of both methods computed on all sensors
- 4) Selection of the $N_{Higuchi}$ and N_{Katz} minimum values of the SA scores $Z_{Higuchi}$ and Z_{Katz} respectively
- 5) Selected scores are used as inputs of a Neural Network with a single hidden layer of 5 neurons
- 6) Training of the Neural Network with the Broyden, Fletcher, Goldfarb, and Shanno (BFGS) algorithm
- 7) Leave-one-out type cross-validation is used

C) Preprocessing

The PLI is removed by FFT based notch filters centered at the fundamental frequency of 60Hz and its harmonics. The selection of the 10 second window is made by removing the first 5 seconds of the experiment. No windowing method were applied since the data length is high (20480). The preprocessing is made one single time without optimization with regards to the classification outcome and therefore does not need to be considered in cross-validation.

D) SA score selection

The lowest $N_{Higuchi}$ and N_{Katz} scores are selected as input vector to the classifier, as shown in fig. 7. The score selection is usually seen as a data reduction method, which is considered as part of the preprocessing of the data. However, its action is equivalent to a competitive layer of a Neural Network with possibly multiple outputs. Since the dimensionality of this layer output $N_{Higuchi}$ and N_{Katz} are optimized, it has to be considered in cross-validation.

The extreme values often bears important information. From an “independent component analysis point-of-view”, the most nonlinear channels are the most “interesting” [23]. From a Neural Network design perspective, it is equivalent to a Max-Pooling layer, a very common and effective approach [24].

The selection of minimum scores over maximum scores was chosen based on visual inspection of the distribution of all scores. There were more very low values than high values. This choice remains arbitrary. There might be interest in maximum values, but this is kept for future works.

The combination of scores are covered exhaustively up to $N_{Higuchi} = N_{Katz} = 10$ (120 combinations overall.)

E) Classification Method

The NN classifier was chosen because its generalization is easily controllable, possibly by a single parameter, can deal easily with a large number of inputs and can manage nonlinear relationships, and even outliers. However, the classifier must be trained using a very small set of data. Hence, overlearning is an issue that must be carefully taken into account. That’s why a Feed Forward NN is used with a single hidden layer with a small number of neurones is used. This NN is presented in fig. 8. The output function of the neurones is the tangent sigmoid.

During the learning process, the Early Stopping procedure and regulation are two techniques that can be used to avoid overlearning. The Early Stopping procedure needs a training set and a validation set. With a small data set, it is difficult to form these two groups. The regulation method adds to the MSE a term proportional to the mean square weight (MSW). This results in the regulated MSE:

$$MSEREG = \gamma MSE + (1 - \gamma) MSW \quad (25)$$

with:

$$MSW = \frac{1}{N_\omega} \sum_{i,j} \omega_{i,j} \quad (26)$$

with $\omega_{i,j}$, the i th neuron of the j th layer, N_ω the total number of weights in the NN and γ the regulation parameter. With proper choice of regulation parameter γ , the MSEREG stabilises after a certain number of iterations. Since the training algorithm works without a validation group, it is a reasonable choice for small samples. However, as discussed later, a cross-validation is still necessary to avoid overlearning.

The optimization technique used is the Broyden-Fletcher-Goldfarb-Shanno (BFGS) algorithm [25] with backtracking line search. The number of iterations for adaptation has been kept constant at 70 epochs. The free parameter γ is made empirically and must be selected for every input set. Adequate cross-validation must therefore take this parameter into account.

F) Cross-Validation

When a large amount of data is available, the training of a NN uses three sets of data: a training set, a validation set and a test set. This is called the holdout method. The training set is used to apply the learning algorithm. The validation step is often seen as only useful for the early stopping method, but in fact it should be used for the optimization or choice of all parameters that are not automatically set by the training process, such as the regulation parameter, structure of the NN and the choice of input. The test set should only be used at the end, to have an unbiased estimate of the classifier capabilities.

With 24 subjects divided in 2 groups, it is not possible to take this three sets approach. It is even difficult to take two sets of data. For this reason, two strategies are taken:

- 1) A leave-one-out cross-validation method is used to emulate a validation set.
- 2) The sensitivity of the performances to the parameter that are selected such as the structure of the NN, the regulation factor and the choice of signal characteristics (number of inputs to the NN) is carefully observed and interpreted instead of having a test set.

Generally, the leave-one-out method would remove a single subject from the training process. However, since the number of data is extremely low, this creates imbalance between the sizes of the two groups. Instead, we applied the leave-one-out method by removing one subject of each group at the same time. We did that for the 144 possible combinations to ensure a well-equilibrated process. This also allows more resolution to the success rates. With the usual leave-one-out, a resolution of 1/24 would be obtained while the resolution attained with the equilibrated approach is 1/144. However, this approach does not otherwise increase the precision of the results since the different trials are not independent.

6. EXPERIMENTAL RESULTS

The performance results are presented with two approach for the regulation parameter γ . First, the best performances on the leave-one out cross-validation, is shown. In this case, the regulation parameter is optimized for every input step. Second, a fixed regulation parameter set at 0.8 is used for every input set. This parameter has been done *a posteriori*. Hence, this produce overestimation of the performances, but as it will be seen, the sensitivity to this parameter at this value is weak.

The performance of the Higuchi's and Katz's methods taken alone with respect to $N_{Higuchi}$ and N_{Katz} Z are shown

in fig. 9. In (a) the regulation parameter is the best for each point while in (b) it is kept constant at 0.8. It is clear for both situations that the information from the Higuchi's method outperform Katz's method. This is also true for all values of $N_{Higuchi}$ and N_{Katz} . While the best success rate obtained by Katz's method is about 0.8, the Higuchi's method can easily give performances above 0.85. The best results obtained by Higuchi, at 0.93 seems exceptional and to representative of the overall performance of the method.

The performances of the combination of $N_{Higuchi}$ and N_{Katz} scores is shown in fig. 10. Again, in (a) the regulation parameter is the best for each point while in (b) it is kept constant at 0.8. The best results are found when a combination of Katz's and Higuchi's scores. Best results are found for $N_{Higuchi} = 2$ and $N_{Katz} = 6$ with success rate of 0.97. However, looking at the bulk of the results, claiming a success rate of 0.9 is more reasonable. It is important to note that the combination of Higuchi's scores with the firsts Katz's scores has worst results than Higuchi's scores alone. Perhaps, the Katz's FD may be less robust to measurement artifacts. Removing the first Katz's scores may be a possible solution to improve all the results. In order to avoid overfitting, this is not done in this paper.

In fig. 11, different combinations of $N_{Higuchi}$ and N_{Katz} near $N_{Higuchi} = 2$ and $N_{Katz} = 6$ are shown with performances presented with respect to the regulation parameter γ . Performances of all the shown combinations are all better than 0.9 for a large region of γ . The results seems therefore somewhat robust to the parameter selections involved. Moreover, for $\gamma = 1$, which is equivalent to remove the regulation, the performances, are still around 0.85, which means that the selection of a very simple Neural Network structure helps strongly to reduce overlearning.

All the success ratios discussed are statistically significant when considering 24 independent samples. For reference, 80% success rate has already a p-value of 0.0033. However, sadly, the comparison of proportion is far from significant. A difference between 80% and 90% requires at least 99 samples to get a 0.05 p-value. Between 85% and 90%, 337 samples would be required. However, the statistical significance is actually not so important in order to support the case that the FD methods are complementary. The fact that the FD does not yield the same results is sufficient to confirm that they give different information. Moreover, on the basis that two features have significant performances and contains different information, it is expected that better results can be obtained by combining them.

7. DISCUSSION

In most papers, even those in which nonlinear features are used for classification, the SA is only used to validate the choice of nonlinear feature over a linear one (e.g. [26-31].) In [8], the idea that the results of the SA could serve as a signal feature that is useful for detection purpose was given. In this paper, while the same approach is used, it is moreover

proposed to exploit the SA to compare the nonlinear information contained in different nonlinear features.

The Z score does not only represent the nonlinearity of the signal. It may be strongly influenced by the non-stationarity. It would be a mistake to interpret it exclusively as a sign of nonlinearity, except perhaps for very simple nonlinear time series as used in this paper. For the experimental data, the interpretation of the SA should be limited as a deviation from the stationary ARMA process null hypothesis. In [32], the SA was used for the detection of non-stationarity. It would be interesting to be able to quantify separately nonlinearity and non-stationarity. However, there might even be a problem in the differentiation of the nonlinearity and non-stationarity. It is possible for instance to have nonlinear time series that on certain scale can be seen as non-stationary. In fig. 5 (b), the Rössler system has two main behaviours. A certain part of the points seems to have no nonlinearity while the bulk of the results shows clear nonlinearity. However, in fig. 5 (c), with more data, no such dichotomy arises. This gives hints of a confusion between nonlinearity and non-stationarity. A full analysis of this phenomenon would be interesting.

There is a windowing effect seen for the numerical experiment since the data length are small. The windowing adds a time-varying relationship. This manly affects the nonlinear series since for the surrogate series, the time domain relationship is randomize. Although the comparison of fig. 5 (b) and fig. 6 showed an obvious benefit of using the windowing method, there is still probably a significant impact on the nonlinear features. Yet, with windowing, the residual effect did not prevent the time series to be very well separated.

Another interesting point seen from fig. 5 (b) is that a single nonlinear feature may not be sufficient to detect nonlinearity. For instance, the Katz's score alone could not detect nonlinearity for the logistic map while Higuchi's score was unaffected by the Henon map. Hence, negative results of a SA test does not mean that the time series is linear.

The comparison of the FDs of fig. 4 and the SA scores of fig. 5 for the three nonlinear series and their surrogate reveals quite convincingly that the SA is a feature much more independent from the linear aspects of the signal. It is not clear however if residual relation between the SA and the Power Spectrum exists.

The fact that very simple or perhaps the simplest nonlinear equations were used to describe the nonlinear complementarity of FD methods support the idea that the conclusions obtained in this paper can be taken as very general rather than restricted to a particular case.

The experimental results shown a good indication of complementarity between the nonlinear features. The interpretation of the results was careful towards avoiding, or at least mitigate the problems associated with the use of multiple models (multiple sets of inputs.) However, with small data sets and multiple trials, there is always a remaining risk of obtaining non-statistically significant difference. Nonetheless, the experiment allowed to illustrate the complementarity of the FD methods. Obviously, similar tests

should be done on larger data set to reinforce the conclusion of the experimental aspects presented in this paper, especially in order to be able to form test groups. It is noteworthy that the different scores are not independent, since they are ordered.

In order to get an equivalent of the three data set, two imbricated leave-one-out methods could have been used, but this process would be extremely time consuming, and would remove even more data for the training. Also, an alternative considered to the BFGS algorithm was the Bayesian Regulation (BR) learning algorithm [33] which requires no adjustable parameter γ (actually, the parameter γ is optimized by the method). The algorithm is well-suited for continuous signals but behave badly for discrete outputs, such as for the classification problem. We noted that the algorithm is often unstable for the dataset. Using multiple initializations of the NN weights allowed having more chance to obtain a stable learning process. However, this did not work for every situation and increased greatly the calculation time. Also, the BR algorithm is in itself already very time consuming.

It was found that the firsts Katz's scores is worsening the Higuchi's scores predictions. One possible explanation is problematic sensors which would produce outliers not detected by Higuchi's method but which would affect the Katz's FD. Since the fractal methods are sensitive to different nonlinear signals, it might be possible one of the method is more sensitive to outliers' signals.

The three regions of the Katz's FD depending on the parameter α has been explained but not deeply analyse and exploited. There is a relation between the data length effect of the parameter that has not been studied. There is also possibility of optimization with respect to the total information extracted by both FD methods. There is even possibly some complementarity between Katz's FD with different α values. In this paper, the objective was limited to show the complementarity between the FD methods. A full analysis of the impact of α was not necessary for this purpose.

Other relations that should be studied more thoroughly in the future are between the Power Spectrum the FD and the SA. The MDF only approximate the information obtained from the Power Spectrum. The effect of bandwidth, cut-off order or multiple pass-band are not include in the MDF but can influence the FDs and SA. Although these relation could be studied on nonlinear time series, doing it on linear time invariant stochastic signals should be already interesting.

Another question is the gain obtained in separating the linear and nonlinear part of the information obtained from FD in a classification problem. Does simply using the MDF and FDs yields as features yields to the same performances than using the MDF, FDs and SA scores together? It is not clear yet if the extracted nonlinear information was already in the FD or part of the relation between the FD and the SA FD distribution. Still, the point of the presented works being that Higuchi's and Katz's methods are complementary would not be changed even if no advantages are found in extracting nonlinear from linear information. Also, from a calculation point-of-view, the SA is extremely costly, needing multiple

IFFT (a single FFT is needed.) Since there is a relationship between the MDF the FD and the SA, it is probably possible to obtain an estimation of the result of the SA from the MDF and FD. In real time application, this could be useful.

8. CONCLUSION

Along with the demonstration that Higuchi's and Katz's FD estimation methods could yield complementary information, the usefulness of the SA as a score was also demonstrated. The approach used to show the complementarity of the FD methods could be used to analyse any other nonlinear feature. Also, the parameters of methods like Grassberger-Procaccia algorithm for Correlation Dimension [34] could be selected by the use of SA in order to extract the most nonlinear information not correlated to that of other methods. The SA scores of the FD methods taken individually were shown to be useful for the practical application of cLBP detection. The Higuchi's method was shown to be superior to the Katz's method which was previously published. It was also clear that for this application, there is an advantage to use both fractal methods. The next major step that would be both interesting from both a theoretical and experimental perspective is perhaps to apply the nonlinear extraction on a multifractal spectrum, the curve length against the scale, which would include the information of both Ktaz's and Higuchi's methods, and probably more.

REFERENCES

- [1] B. B. Mandelbrot, "The fractal geometry of nature (Vol. 1)", New York: WH freeman, 1982.
- [2] M. Katz. "Fractals and the analysis of waveforms". Computers in Biology and Medicine, vol. 18, no. 3, pp. 145-156, 1988.
- [3] T. Higuchi. "Approach to an irregular time series on the basis of the fractal theory", Physica D: Nonlinear Phenomena, vol. 31, no. 2, pp. 277-283, 1988.
- [4] P. Castiglioni. "What is wrong in Katz's method? Comments on: "A note on fractal dimensions of biomedical waveforms"". Computers in Biology and Medicine, vol. 40, no. 11-12, pp. 950-952, 2010.
- [5] T. Higuchi, "Relationship between the fractal dimension and the power law index for a time series: A numerical investigation", Physica D: Nonlinear Phenomena, vol. 46, no. 2, pp. 254-264, 1990.
- [6] R. Esteller, G. Vachtsevanos, J. Echauz and B. Litt, "A comparison of waveform fractal dimension algorithms", IEEE Transactions on Circuits and Systems I: Fundamental Theory and Applications, vol. 48, no. 2, pp. 177-183, 2001.
- [7] J. Theiler, S. Eubank, A. Longtin, B. Galdrikian, J. D. Farmer. "Testing for nonlinearity in time series: the method of surrogate data," Physica D: Nonlinear Phenomena, 58(1-4), 77-94, 1992.
- [8] M. Caza-Szoka, D. Massicotte, F. Nougarou, M. Descarreaux. "Surrogate analysis of fractal dimensions from SEMG sensor array as a predictor of chronic low back pain", In Engineering in Medicine and Biology Society (EMBC), 2016 IEEE 38th Annual International Conference of the, pp. 6409-6412, 2016.
- [9] K. Lalanne, D. Lafond, M. Descarreaux, "Modulation of the flexion-relaxation response by spinal manipulative therapy: a control group study." Journal of manipulative and physiological therapeutics, vol. 32, no 3, pp. 203-209, 2009.
- [10] C. Lariviere, A. B. Arsenault, D. Gravel et al., "Evaluation of measurement strategies to increase the reliability of EMG indices to assess back muscle fatigue and recovery," Journal of Electromyography and Kinesiology, vol. 12, no 2, pp. 91-102, 2002.
- [11] M. Caza-Szoka, D. Massicotte, F. Nougarou, "Naive Bayesian learning for small training samples: Application on chronic Low Back Pain diagnostic with sEMG sensors", In Instrumentation and Measurement Technology Conference (I2MTC), 2015 IEEE International, pp. 470-475, 2015.
- [12] M. González-Izal, A. Malanda, E. Gorostiaga and M. Izquierdo. "Electromyographic models to assess muscle fatigue", Journal of Electromyography and Kinesiology, vol. 22, no. 4, pp. 501-512, 2012.
- [13] A. Coelho and C. Lima, "Assessing fractal dimension methods as feature extractors for EMG signal classification", Engineering Applications of Artificial Intelligence, vol. 36, pp. 81-98, 2014.
- [14] M. Affinito, M. Carrozza, A. Accardo and F. Bouquet, "Use of the fractal dimension for the analysis of electroencephalographic time series", Biological Cybernetics, vol. 77, no. 5, pp. 339-350, 1997.
- [15] B. Raghavendra and D. Narayana Dutt, "A note on fractal dimensions of biomedical waveforms", Computers in Biology and Medicine, vol. 39, no. 11, pp. 1006-1012, 2009.
- [16] S. Pincus, "Approximate entropy as a measure of irregularity for psychiatric serial metrics", Bipolar Disorders, vol. 8, no. 51, pp. 430-440, 2006.
- [17] R. May, "Simple mathematical models with very complicated dynamics", Nature, vol. 261, no. 5560, pp. 459-467, 1976.
- [18] M. Hénon, "A two-dimensional mapping with a strange attractor", Communications in Mathematical Physics, vol. 50, no. 1, pp. 69-77, 1976.
- [19] O. Rössler, "An equation for continuous chaos", Physics Letters A, vol. 57, no. 5, pp. 397-398, 1976.
- [20] T. Suzuki, T. Ikeguchi, and M. Suzuki, "Effects of data windows on the methods of surrogate data," Physical Review E, vol. 71, no. 5, 2005.
- [21] P. Bloomfield. "Fourier Analysis of Time Series: An Introduction". New York: Wiley-Interscience, 2000.
- [22] T. Ito, O. Shirado, H. Suzuki, M. Takahashi, K. Kaneda and T. Strax, "Lumbar trunk muscle endurance testing: An inexpensive alternative to a machine for evaluation", Archives of Physical Medicine and Rehabilitation, vol. 77, no. 1, pp. 75-79, 1996.
- [23] J.V. Stone, "Independent component analysis : a tutorial introduction". Cambridge, Massachusetts: MIT Press, 2004.
- [24] D. Cireşan, U. Meier, J. Masci and J. Schmidhuber, "Multi-column deep neural network for traffic sign classification", Neural Networks, vol. 32, pp. 333-338, 2012.
- [25] J.E. Dennis, and R.B. Schnabel, Numerical Methods for Unconstrained Optimization and Nonlinear Equations, Englewood Cliffs, NJ: Prentice-Hall, 1983.
- [26] C. Stam, "Nonlinear dynamical analysis of EEG and MEG: Review of an emerging field", Clinical Neurophysiology, vol. 116, no. 10, pp. 2266-2301, 2005.
- [27] R. Andrzejak, K. Lehnertz, F. Mormann, C. Rieke, P. David and C. Elger, "Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state", Physical Review E, vol. 64, no. 6, 2001.
- [28] M. Costa, A. Goldberger and C. Peng, "Multiscale entropy analysis of biological signals", Physical Review E, vol. 71, no. 2, 2005.
- [29] D. Subha, P. Joseph, R. Acharya U and C. Lim, "EEG Signal Analysis: A Survey", Journal of Medical Systems, vol. 34, no. 2, pp. 195-212, 2008.
- [30] J. Jeong, "EEG dynamics in patients with Alzheimer's disease", Clinical Neurophysiology, vol. 115, no. 7, pp. 1490-1505, 2004.
- [31] A. Porta et al., "Entropy, entropy rate, and pattern classification as tools to typify complexity in short heart period variability series". IEEE Transactions on Biomedical Engineering, vol. 48, no. 11, pp. 1282-1291, 2001.
- [32] J. Timmer, "Power of surrogate data testing with respect to nonstationarity," Physical Review E, vol. 58, no. 4, pp. 5153-5156, Jan. 1998.
- [33] Foresee, F. Dan, and Martin T. Hagan. "Gauss-Newton approximation to Bayesian learning." Proceedings of the International Joint Conference on Neural Networks, June, 1997.
- [34] P. Grassberger and I. Procaccia, "Measuring the strangeness of strange attractors", Physica D: Nonlinear Phenomena, vol. 9, no. 1-2, pp. 189-208, 1983.

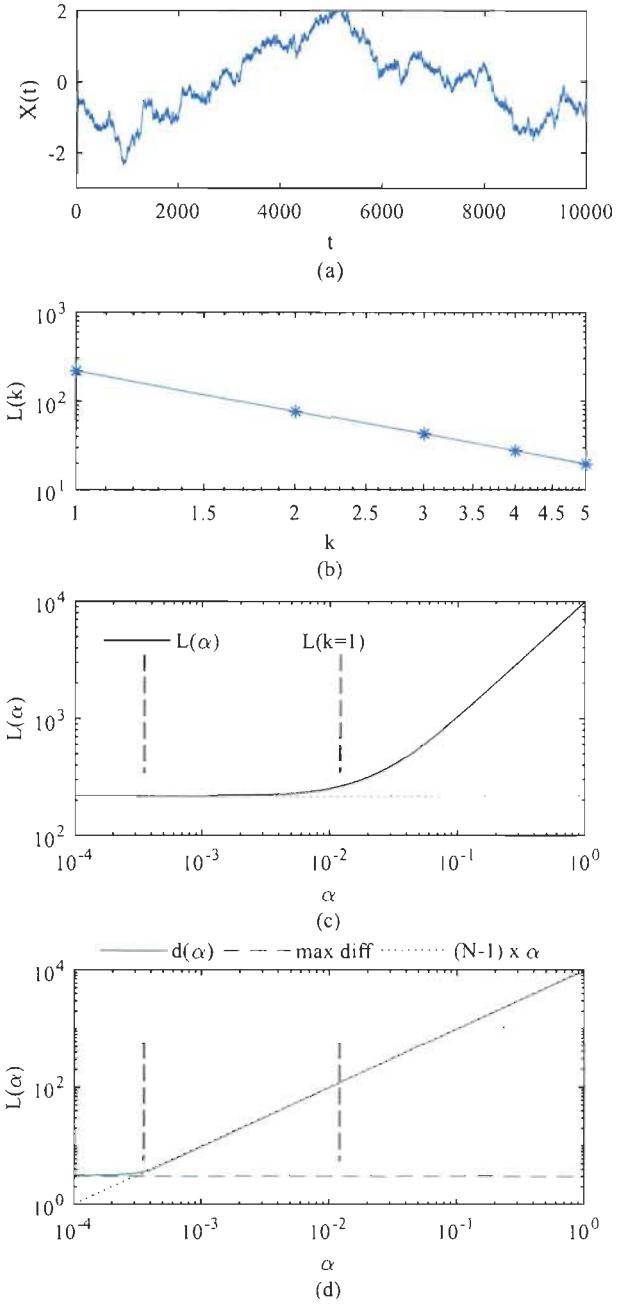


Fig. 1 Illustration of the relations between the Higuchi's and Katz's and Higuchi's FD estimation methods for the Brownian motion. The test signal is shown in (a). In (b), the curve length L is plotted against the subsampling factor k . This is used for the calculation of Higuchi's FD. The elements L_T and d necessary to Katz's FD calculation are plotted against the parameter α in (c) and (d) respectively. The L_T is shown along with the curve length with no subsampling from Higuchi's method for reference while d is shown with the maximum absolute difference between any value and the first and the $(N-1)$ time α , equivalent to the total time of the time series. The three regions related to the parameter α are delimited in (c) and (d).

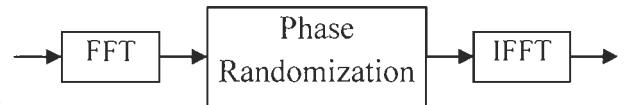


Fig. 2 The process of creating a surrogate time series is done by applying the FFT, randomizing the phase and applying the IFFT. It gives a new time series with the same power spectrum. The surrogate data however does not contain nonlinearities or time-varying characteristics.

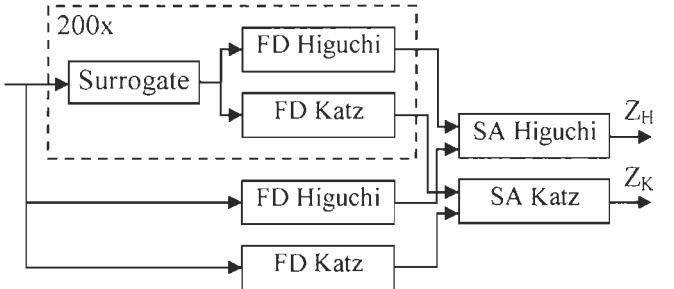
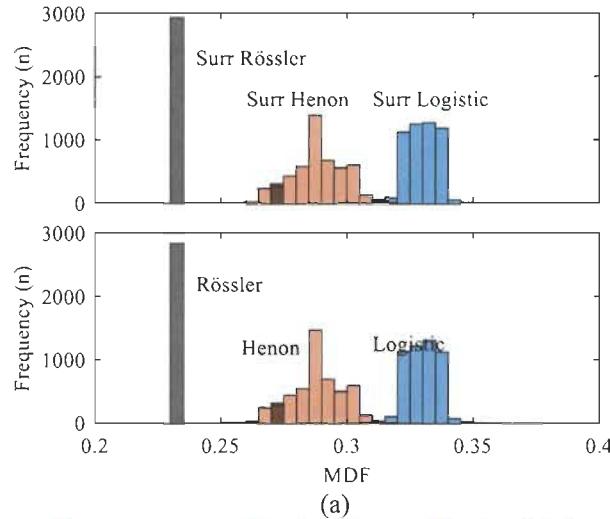
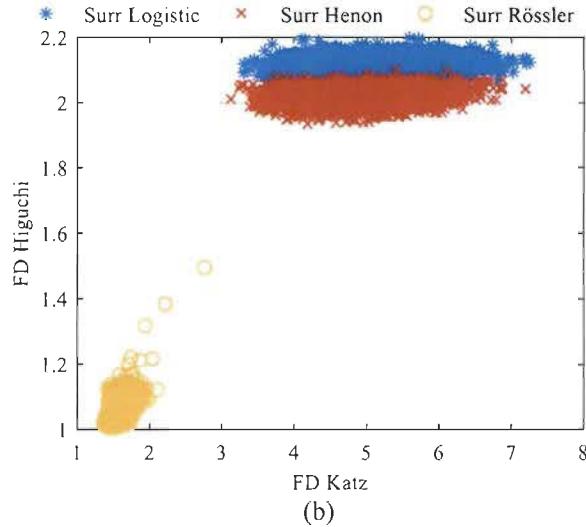


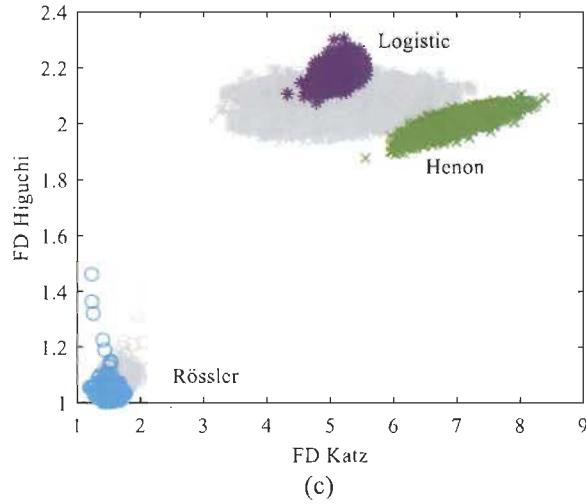
Fig. 3 The Z scores are obtained by comparing the FD of the original time series to the FD from the surrogate time series. Here, in order to have the distribution of the possible FD of the surrogate signals, 200 surrogate signals are produced and theirs FDs are obtained for the two fractal methods. Let's note that the same surrogate time series are used for the two methods in order to reduce the complexity.



(a)



(b)



(c)

Fig. 4 MDF and FD of the three nonlinear time series and their surrogate series for data length of 256. In (a), the histogram of the MDF of the three nonlinear series and their surrogate are shown. In (b), the FD obtained by Katz's and Higuchi's FD methods are plotted one against the other only the results of the three surrogate series are shown. In (c), the results of the nonlinear series are added and the results of the surrogate series are shade.

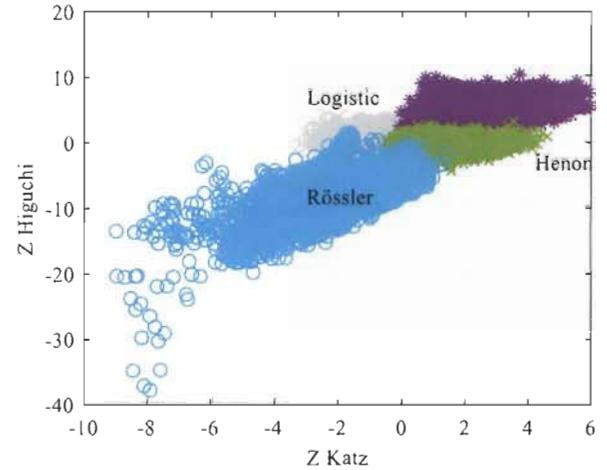
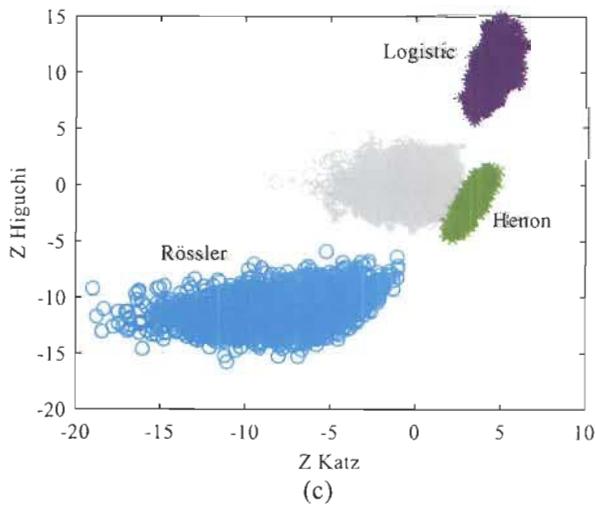
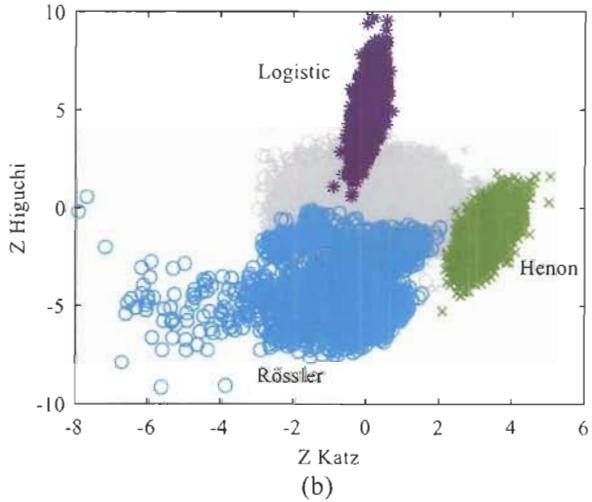
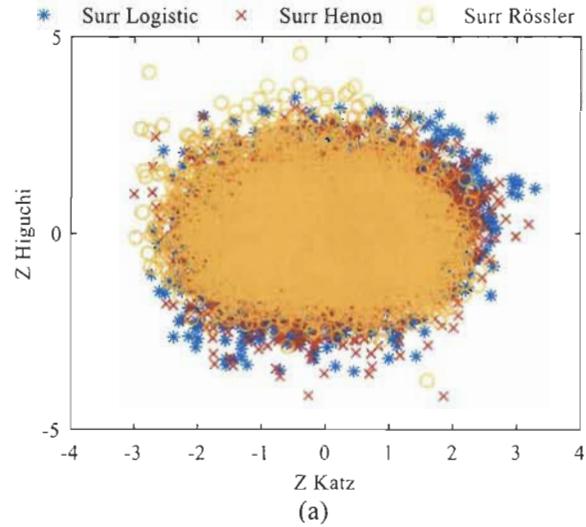


Fig. 6 SA of the three nonlinear time series and their surrogate series without windowing method.

Fig. 5 SA of the three nonlinear time series and their surrogate series. The Z scores obtained by Katz's and Higuchi's FD methods are plotted one against the other. In (a), only the results of the three surrogate series are shown for data length of 256. In (b), the results of the nonlinear series are added and the results of the surrogate series are shaded for data length of 256. In (c), the data length is set to 1024.

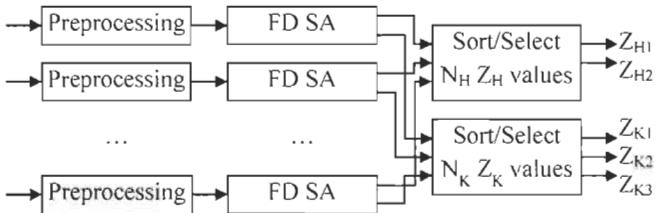


Fig. 7 After the preprocessing and extraction of Z scores by Fractal Dimension Surrogate Analysis (FD SA), the results of all the channels are sorted. A selection of N_H scores Z_H and N_K scores Z_K with the lowest values is made. The figure presents the case where 2 scores from the Higuchi's method and 3 scores from the Katz's method are taken. The same process is made for both sensor arrays (left and right).

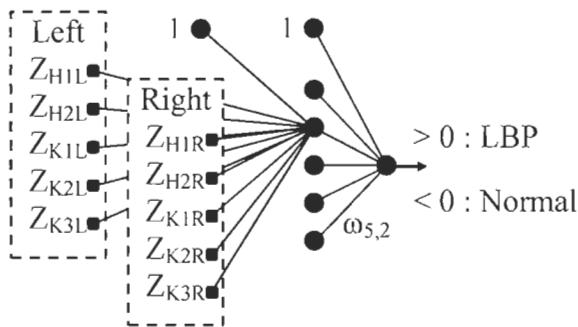
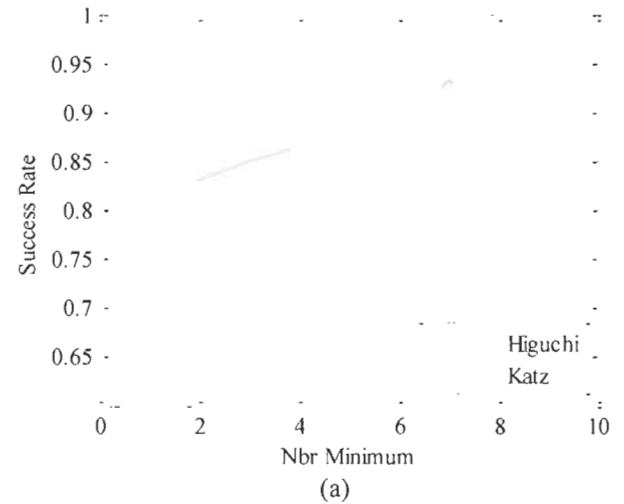
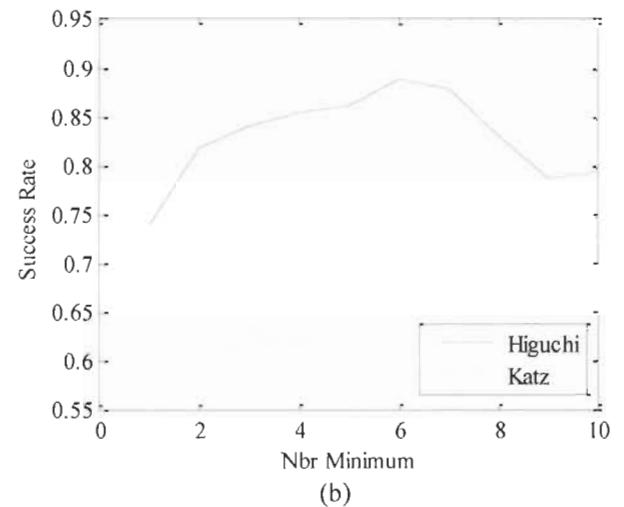


Fig. 8 The selected scores Z_H and Z_K are the signal characteristics used as inputs to the fully connected Feed Forward Neural Network. The left and right sensor arrays give their own sets of characteristics. The connection of the inputs layer neurones to the hidden layer are only shown for one hidden layer neuron. The figure presents the case where 2 scores from the Higuchi's method and 3 scores from the Katz's method are taken. Hence, there is a total of 10 inputs to the NN.

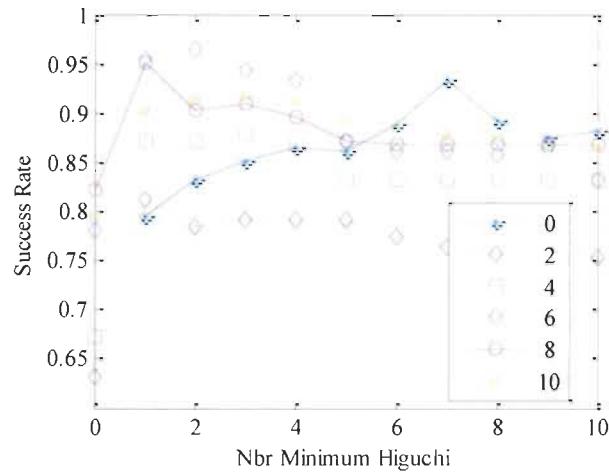


(a)

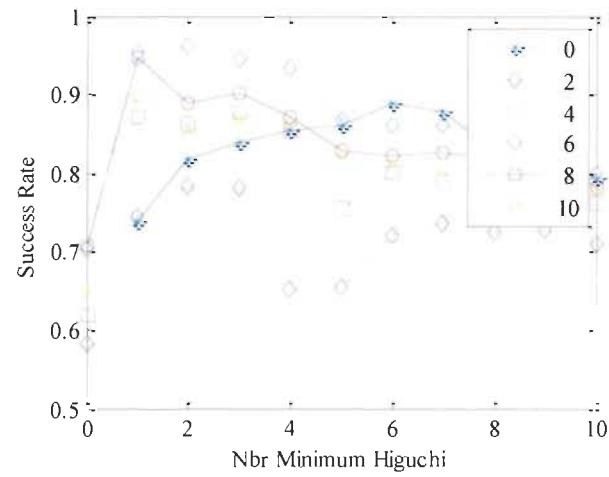


(b)

Fig. 9 Comparison of the success rate as a function of the number of Z scores for either Higuchi's method or Katz's method. In (a) the regulation parameter is the best for each point while in (b) it is kept constant at 0.8.



(a)



(b)

Fig. 10 Comparison of the success rate as a function of the number of $Z_{Higuchi}$ scores for different number of Z_{Katz} . This graphic allows visualizing the combine effect of the different possible sets of input characteristics. In (a) the regulation parameter is the best for each point while in (b) it is kept constant at 0.8.

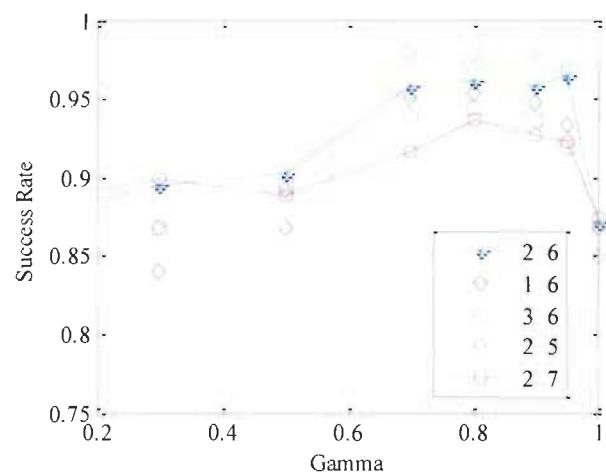


Fig. 11 Comparison of the success rate as a function of the regulation parameter (γ) for different sets of input characteristics around $N_{Higuchi} = 2$ and $N_{Katz} = 6$. The different line represents the performances of different input sets.

Windowing Compensation in Fourier Based Surrogate Analysis

Manouane Caza-Szoka, Daniel Massicotte, François Nougarou

Abstract—This paper shows how adding a second step of windowing after each phase randomization can reduce the False Rejection Rate in Fourier based Surrogate Analysis. Windowing techniques improve the resolution of the Power Spectrum estimation by reducing the sampling gap caused by the periodic extension of the Fourier Series. However, it adds a time domain non-stationarity which affects the Surrogate Analysis. This effect is particularly problematic for short low-pass signals. Applying the same window to the surrogate data allow having the same non-stationarity. The method is tested on order 1 autoregressive process null hypothesis by Monte-Carlo simulations. Previous methods were not able to yield good performances for left-sided and right-sided tests at the same time, even less with bilateral tests. It is shown that the new method is conservative for unilateral tests as well as bilateral tests.

Index Terms—LTV, Surrogate Analysis, Nonlinear Analysis, Windowing

I. INTRODUCTION

THE Surrogate Analysis (SA) is a statistical test aimed at assessing the nonlinear nature of a signal. It has been applied to a wide variety of domain [2], notably in the study of brain activity [3][4]. More recently, it has been used for Low-Back-Pain diagnostic with electromyogram (EMG) sensors [5].

When the data length is limited, windowing techniques improve the resolution of the Power Spectrum estimation needed for the generation of surrogate series in Fourier based SA by reducing the sampling gap caused by the periodic extension of the Fourier Series. In [6], the windowing is applied in the generation of the surrogates. However, these surrogate are compared to the *unwindowed* original series. This leads to a spreading in the power spectrum of the surrogate which is not present in the original signal, producing a bias. The results showed the trade-off between reducing the sampling gap and avoiding the frequency spreading. Indeed, it indicated that using the windowing techniques is useful up to a certain data length. Above, the windowing worsen the bias. Moreover, even in the best cases, it remained largely optimistic, yielding between 10 and 25% of False Rejection Rate (FRR) when a 5% rate would be expected. Nonetheless, it is clear that windowing is important: without it, the FRR were shown to be over 30%.

A different approach would be to compare the surrogate to the windowed version of the original signal. However, the windowing process adds time domain non-stationarity. The windowing of a stationary ARMA process makes its variance changing from sample to sample. It has been shown that the SA

may be very sensitive to non-stationarity [7]. This effect has even been exploited in [8]. The non-stationarity caused by the windowing in the original data will not be present in the surrogate series. Clearly, the windowing adds a bias. The biases in SA make either the left or right sided test over-optimistic. Also, it makes the bilateral tests always over-optimistic. The bilateral tests are important when the type of nonlinearity that might be present is unknown.

This paper presents a method for compensating the non-stationarity caused by the windowing in surrogate analysis. The method consists of keeping the window on the original series and applying the same window on every surrogate data series. This adds the same non-stationarity to the surrogate series as in the original series. The analysis is conduct by Monte-Carlo simulations on an order 1 autoregressive process (AR(1)) as in [6], but considering the unilateral and bilateral tests. Although the added windowing replaces the sampling gap artifact by a frequency smoothing artifact, it will be shown that the overall effect is conservative.

II. SURROGATE ANALYSIS AND WINDOWING

The SA compares a nonlinear feature, such as the Fractal Dimension (FD) [9] used in this paper, of a signal to the distribution same feature obtained on random signals with identical Power Spectrum. To do this, surrogate signals respecting the null hypothesis with the same power spectrum as the originals signals must be generated. The most common approach, which is considered here, is the phase randomization in the frequency domain. First, the Fast Fourier Transform (FFT) is applied. The phase is set to a uniform distribution between 0 and 2π , with conjugate symmetry in order to preserve real values. Then, the signal is set back in the time domain by inverse Fourier transform (IFFT).

For a unilateral test with an aimed 5% FRR, 19 such surrogate series are generated. The FD is calculated for every surrogate series. The final stage is a comparison between the FD of the original series to those of the surrogate. A positive result to the test is given if the original series FD is higher than the surrogate series FD when the test is right sided and lower when the test is left sided. For a bilateral test, the number of surrogate series must be increased at 39 and the test will be positive if the original FD is higher of lower than all the surrogate series FD.

The null hypothesis is that the signal can be produced by a stationary linearly filtered white Gaussian noise. If the data processing produces some kind of artifacts that are not of an

ARMA type, these may influence the results.

When windowing is applied on a signal, two effects must be considered:

1) The spreading of the power spectrum (explained by the convolution theorem)

2) A non-stationarity in the variance of the signal.

These two effects can affect the nonlinear feature of the signal. It is important to note that non-stationarity is removed by phase randomization. If some windowing artifact are present in the original signal but not in the surrogate (or the reverse), a bias is created.

The four systems presented in Fig. 1 show different approaches for applying windowing in SA. The systems are shown for right-sided tests with FRR set at 0.05 (if the test was unbiased). The rest of the present sections describes the first three systems used as a basis of comparison and the proposed system.

A. System 1: Windowless Surrogate Analysis

The basic SA without windowing is presented in Fig. 1 (a). It is the system mostly used throughout the literature proposed in [1]. It can be interpreted as using a rectangular window. Here, the main differences between the original signal and its surrogate are the sampling gap and correlation between the frequency bins phases [1]. Although there is a very high spreading of the Power Spectrum, it is identical between the original and the surrogate signals.

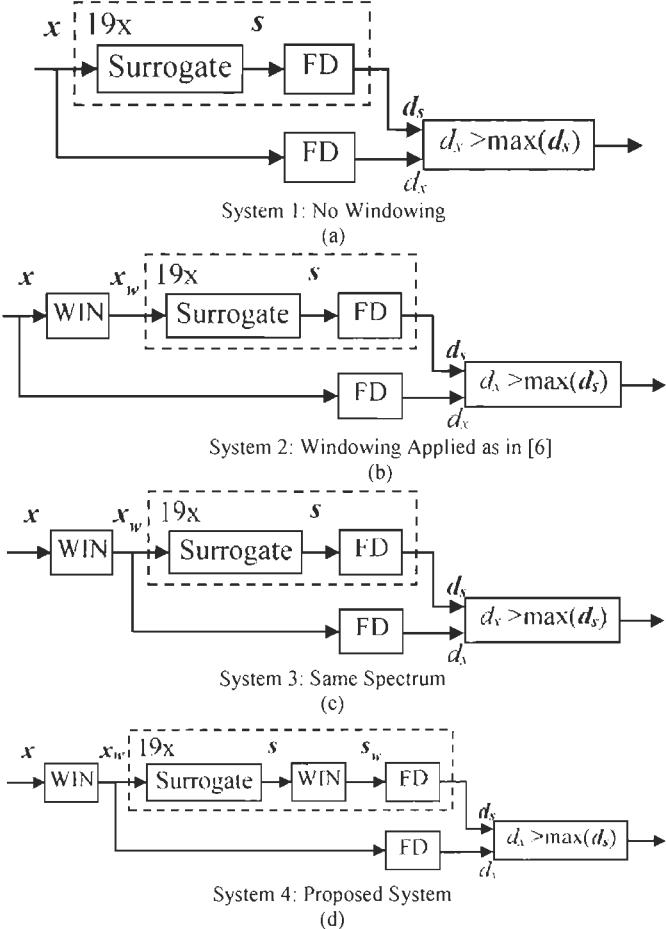


Fig. 1. Windowing in the surrogate analysis system for right-sided tests. The system with no windowing is presented in (a). The method used in [6] is shown in (b), with the only difference being that the FD is used instead of Local Linear Prediction. The system in (c) is a variation of the previous one in which the FD of the original series is obtained from the windowed original series.

B. System 2: Method of Suzuki [6]

In Fig. 1 (b), the windowing is applied before the FFT. However, the FD of the original series is calculated on the *unwindowed* version. Although the sampling gap effect is strongly reduced, the Power Spectrum differs between the original and surrogate series. Moreover, this difference is identical throughout the surrogate series. On the other hand, all the signals are stationary. The method was first briefly mentioned in the original SA paper [1] but was really analyzed in [6].

C. System 3: For the Sake of Completion

A final reference method is given in Fig. 1 (c). The system is similar to the method in (b), but the FD of the original series is calculated on the *windowed* version. Therefore, the original and surrogate series have the same Power Spectrum. However, while the surrogate series are stationary, the windowed original signal is not. This method has not been found in literature. Although it is an obvious variant with the System 2, it is included in the numerical tests for the sake of completion, because it shows a situation where the only artifact is the non-stationarity.

D. System 4: Proposed Windowing Method for Surrogate Analysis

The proposed system is reported in Fig. 1 (d). The difference with (c) is that a second windowing stage is added to the surrogate series before calculating the FD. The two main relations between the original and surrogate series are:

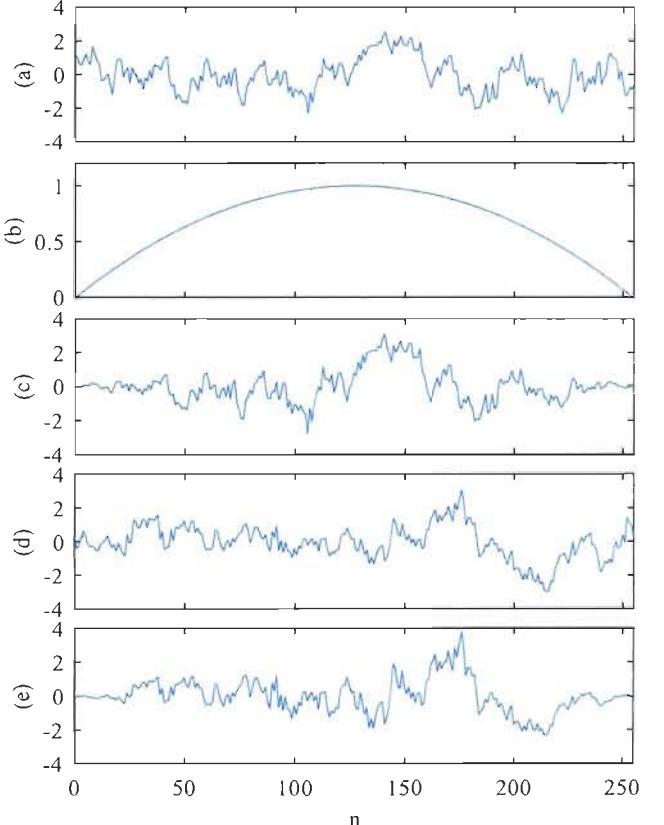


Fig. 2. Time domain representation of an example of 256 data points of an AR(1) signal with $\alpha_1 = 0.9$ and its processed versions by the proposed system. The signal variables are given with respect to the proposed system shown in Fig. 1 (d). The figure presents the original signal x (a), the Welch window (b), the original windowed signal x_w (c), a surrogate of the windowed signal s (d) and the windowed surrogate signal s_w (e).

- 1) The non-stationarities are similar
- 2) The difference of the Power Spectrums are different between the surrogates.

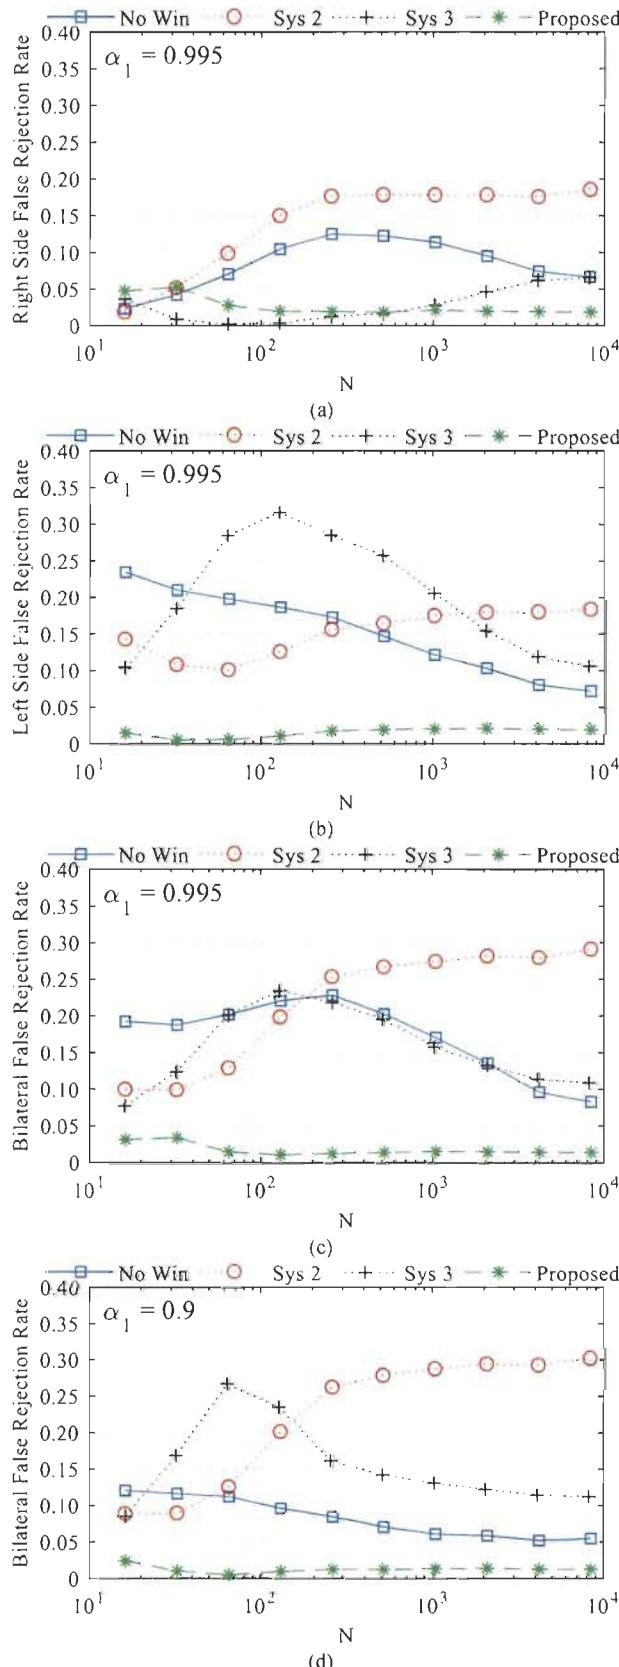


Fig. 3. False Rejection Rates vs. the number of data points (window size) of all systems for an AR(1) process with $\alpha_1 = 0.995$ for (a-c). Right-sided (a), left-sided (b) and bilateral (c) tests are shown. In (d), the process has $\alpha_1 = 0.9$ and the test is bilateral. The number of tests was 20000 per points.

The second aspect adds variability in the surrogate series. The Power Spectrums of the surrogate will be approximately centered to the windowed original signal's Power Spectrum. For this reason, it is expected that the test will be more conservative.

Examples of the different signals obtained in the System 4 are shown in Fig. 2 (a) (c-e) along with the window used (b). It is clear that the windowed signal have similar non-stationarity.

III. NUMERICAL TESTS METHODOLOGY

This section describes the conditions and results of the numerical experiments done by Monte-Carlo simulations.

A. Nonlinear Method

The nonlinear method used in this paper is the FD calculated by the Higuchi's method [9]. A similar use of FD in the context of SA was notably used in [10] for magnetoencephalography (MEG) signals. The FD is easily calculated, even with a low number of data points. The method necessitates the selection of the time intervals (k). For speed, we only used k from 1 to 5.

B. Window

In [6], different windows were tested. In this paper different systems are tested. Hence, the best window proposed in [6], the Welch Window, is used throughout this paper. The Welch Window is a parabola centered at $N/2$, as shown in Fig. 2 (b):

$$(n) = 1 - \left(\frac{2n-(N+1)}{N-1} \right)^2 \quad (1)$$

C. Test Signal

The AR(1) process is used for the tests. It follows the relation:

$$x(n) = \alpha_1 x(n-1) + e(n) \quad (2)$$

where x is the signal, α_1 is the process parameter controlling the cut-off frequency and e is an independent identically distributed random variable called process noise. In this paper, the noise has a normal distribution. This process was used in [6] with $\alpha_1 = 0.995$. This choice was appropriate in order to highlight the windowing effect. The sampling gap in FFT is much more obvious in low pass signals. We used the same α_1 in most of this paper analysis. However, we also show results with $\alpha_1 = 0.9$, which clearly reduce the sampling gap problem and give an advantage to the System 1, with no windowing. An AR(1) process with $\alpha_1 = 0.9$ is shown in Fig. 1 (d). As in [6], the first data were removed in order to attain the steady state regime. The transient regime can be seen as non-stationary, which can affect the SA. We used an extra 2000 data points in order to have a relative impact of 5E-5 in the case where $\alpha_1 = 0.995$.

D. Performance Measure: The False Rejection Rate

The FRR is used to compare the performances of the different systems. It is often called "Type I error." A perfectly fair, or balanced test should give a FRR of exactly 5%. When the FRR is lower, the test is considered conservative while if it is higher, the test is said to be optimistic.

E. Monte-Carlo Simulations

Monte-Carlo simulations were conducted in order to obtain the FRR of the different systems. The number of tests per point in these graphs was 20000. The same signals were tested for every methods. This gives a maximum error of 1% at 3 standard deviations when the FRR is of 50% and 0.2% when FRR is at 5%. In the first simulation, α_1 was set to 0.995. These are shown in Fig.3 (a-c). The right-sided (a), left-sided (b) and bilateral tests results are shown. In (d), the results for the bilateral test is given for $\alpha_1 = 0.9$.

IV. RESULTS

A bias in the FD of the surrogate will reduce the FRR of one of the one-sided test while increasing the FRR of the other. For example, the System 3 shows a really low FRR for the right-sided test in Fig. 3 (a) but very high for the left-sided test. The effect of the bias for bilateral test is harder to predict. When a normal distribution is considered, the bias simply increase the FRR. However, when the distribution is skewed, the FRR can be either lowered or raised (or in some particular case stayed unaffected.) Adding some Kurtosis effects, it becomes necessary to simply rely on simulations to assess the impact of the different biases. In Fig. 3 (a-c), the System 2 bilateral test has some FRRs higher than for both one-sided tests while the system 3 does not. The relation between the standard deviation of the offsets and standard deviation of the surrogates FDs will impact both one-sided tests, as well as the bilateral test.

The results shows that the proposed system is generally very conservative. Since the right-sided tests FRR is higher than for the left-sided tests, there is still a weak bias. The bilateral test FRR is almost always at 1%. The proposed system is the only one which can give conservative results in bilateral tests.

When $\alpha_1 = 0.9$ (d), the impact of not using windowing (System 1) is much weaker, as expected. Also, as the number of data point increase, the windowing problem disappear. The number of data points necessary to remove the need of windowing depends on the bandpass of the signal, controlled by α_1 in this case. The System 2 has the same kind of behaviour with FD that it had with Local Linear Prediction as reported in [6]. It has better performances than System 1 (no window) when the number of data points is small, but worse when the number is higher. Although the System 3 performs better than System 2 when the number of data points is high, it almost never performs better than the System 1 and 2 simultaneously.

V. DISCUSSION

The results shown in this paper where based on a certain nonlinear method (FD), a particular window (Welch) and a specific type of signal, the AR(1) process with very low pass characteristics. It must be emphasized that every time the SA is used, a careful examination of the null hypothesis should be carried out with the selected nonlinear method and window on signals with similar power spectrum as the data. In other words, the analysis carried out in this paper should be done for any new combination of nonlinear function, window and signal. The SA should never be used blindly [12]. As it should be reminded in

every paper about the SA, the interpretation of the results must be limited to rejecting or not that “a linear, Gaussian, stationary, stochastic dynamical process underlies the data” [13].

In this paper, we used the Welch’s window because it was the recommended window in [6]. However, this choice may be improved for the proposed system. Obviously, the optimal window depends strongly on the nonlinear method used and the type of signal analysed.

Finally, the SA has a variant in which the null hypothesis includes a static (memoryless) monotonic nonlinear transform called Amplitude Adjusted Surrogate Analysis (AASA) [1][6]. The proposition of this paper can be extended to this variant with the same expected benefits.

VI. CONCLUSION

The aim of this paper was not to show a ready-to-use method to detect nonlinearity. Rather, it proposed a system that must be adapted and tested every time nonlinear analysis is used when the number of data is limited. The method proposed, although very conservative, allows to rule out the effect of windowing of the already complicated interpretation of the surrogate analysis.

REFERENCES

- [1] J. Theiler, S. Eubank, A. Longtin, B. Galdrikian, and J. D. Farmer, “Testing for nonlinearity in time series: the method of surrogate data,” *Physica D: Nonlinear Phenomena*, vol. 58, no. 1-4, pp. 77–94, 1992.
- [2] E. Bradley and H. Kantz, “Nonlinear time-series analysis revisited.” *Chaos: An Interdisciplinary Journal of Nonlinear Science*, vol. 25, no. 9, p. 097610, 2015.
- [3] C. Stam, “Nonlinear dynamical analysis of EEG and MEG: Review of an emerging field,” *Clinical Neurophysiology*, vol. 116, no. 10, pp. 2266–2301, 2005.
- [4] R. G. Andrzejak, K. Lehnertz, F. Mormann, C. Rieke, P. David, and C. E. Elger, “Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state,” *Physical Review E*, vol. 64, no. 6, 2001.
- [5] M. Caza-Szoka, D. Massicotte, F. Nougarou, and M. Descarreaux, “Surrogate analysis of fractal dimensions from SEMG sensor array as a predictor of chronic low back pain.” 2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), 2016.
- [6] T. Suzuki, T. Ikeguchi, and M. Suzuki, “Effects of data windows on the methods of surrogate data,” *Physical Review E*, vol. 71, no. 5, 2005.
- [7] J. Theiler, “Spurious dimension from correlation algorithms applied to limited time-series data,” *Physical Review A*, vol. 34, no. 3, pp. 2427–2432, Jan. 1986.
- [8] J. Timmer, “Power of surrogate data testing with respect to nonstationarity,” *Physical Review E*, vol. 58, no. 4, pp. 5153–5156, Jan. 1998.
- [9] T. Higuchi, “Approach to an irregular time series on the basis of the fractal theory,” *Physica D: Nonlinear Phenomena*, vol. 31, no. 2, pp. 277–283, 1988.
- [10] C. Gómez, Á. Mediavilla, R. Hornero, D. Abásolo, and A. Fernández, “Use of the Higuchi fractal dimension for the analysis of MEG recordings from Alzheimers disease patients,” *Medical Engineering & Physics*, vol. 31, no. 3, pp. 306–313, 2009.
- [11] K. T. Dolan and M. L. Spano, “Surrogate for nonlinear time series analysis,” *Physical Review E*, vol. 64, no. 4, 2001.
- [12] D. Kugiumtzis, “Test your surrogate data before you test for nonlinearity,” *Physical Review E*, vol. 60, no. 3, pp. 2808–2816, Jan. 1999.
- [13] J. Timmer, “What Can Be Inferred from Surrogate Data Testing?,” *Physical Review Letters*, vol. 85, no. 12, pp. 2647–2647, 2000.

SENSITIVITY OF THE SURROGATE ANALYSIS METHOD TO SYNCHRONIZATION AND CONDUCTION VELOCITY OF MUSCULAR FIBERS

Manouane Caza-Szoka, Daniel Massicotte

Université du Québec à Trois-Rivières, Electrical and Computer Engineering Department
C.P. 500, Trois-Rivières, Québec, Canada, G9A 5H7, www.uqtr.ca/lssi
{manouane.caza-szoka, daniel.massicotte }@uqtr.ca

Abstract— This paper shows that conduction velocity (CV) and motor unit action potential (MUAP) synchronisation affects the results of Surrogate Analysis (SA). These findings can be used to 1) interpret the result of the surrogate analysis and 2) help evaluate the CV and MUAP synchronisation. A simple dipole based model for EMG signal simulation is used. It is composed of multiple fibers superposed at the same location, leaving aside any complex geometrical considerations, but putting the emphasis on the timing of the MUAPs firing. Single pulse synchronisation as well as impulse train synchronisation are studied. To highlight the difference between spectral (linear) features, nonlinear features and SA relation with the model parameters, the Median Frequency (MDF), the Kurtosis, the Higuchi's Fractal Dimension (FD) and the FD based SA are compared. The simulation results show that the SA is jointly influenced by CV and the MUAP synchronisation, almost in a multiplicative way. These relations are also more pronounced for an impulse train than for a single pulse. Overall, the SA is shown to be a good feature to consider for CV and synchronisation estimation, uncorrelated with spectral features and moderately with nonlinear features.

Keywords— Fractal, Features extraction, sEMG sensors, Synchronization, Nonlinear analysis, Hypothesis testing

1. INTRODUCTION

The Conduction Velocity (CV) and Synchronisation of the Motor Unit Action Potential (MUAP) have been studied for in order to investigate their relations with muscular fatigue [1][2]. The CV and MUAP synchronisation estimation are therefore of particular interest. These problems have been tackled by spectral (linear) [1] and non-linear features [3-5]. However, it is well known that often linear and nonlinear features can be strongly correlated [6].

The problem of the relation between the power spectrum and nonlinear features is commonly studied by Surrogate Analysis (SA) [7]. The SA is a statistical test which can determine if the value of a nonlinear feature could be obtained from a random time series with similar power spectrum.

The straightforward interpretation [8] of the result is “the nonlinear feature of the time series could not likely have been obtained from a stationary random autoregressive (ARMA) process with the same power spectrum.” More loosely, an interpretation linked to the nonlinear feature is often given. Such interpretation have been suggested for EMG signals in [9] where the conclusion that “nonlinear dynamic characteristic can be detected from small data sets of different action surface EMG signals” was drawn.

In this paper, it is suggested that the synchronisation of MUAP is an interesting interpretation of the SA which is linked to the EMG rather than the nonlinear feature.

A common approach to evaluate feature performances is the use of simulation where all parameters are known and can be modified independently [10]. Therefore, to highlight the properties of the SA in relation to the CV and synchronization, a very simple, comprehensive model is used. The MUAPs are models as dipoles travelling in an infinite fibre, with the same amplitude and shape and CV. The fibers are modeled to be at the same location, reducing the number of simulation free parameters. Simulations are produced for different CVs, different number of MUAPs, different time windows, for single synchronised impulse timing and impulse train. The effect of the imperfection of synchronisation, modeled as a normal distribution, is also addressed. For each setup, the MDF, the Higuchi's fractal dimension (FD) and the Higuchi's FD based SA are calculated by Monte-Carlo Simulation. It is shown that the Higuchi's FD (FD) based SA is sensitive MUAPs synchronisation. This relation is moreover sensitive to many parameters, particularly the CV where a multiplicative like effect can be observed.

The paper is organized as follows: the numerical methods are described in Section 2 while the simplified EMG model is presented in Section 3. The simulations parameters and results are reported in Section 4 and discussed in Section 5. Finally, Section 6 draws some conclusions.

2. LINEAR AND NONLINEAR METHODS

This section details the linear and nonlinear features used in this paper. The simpler methods are used for comparison purpose against the more complex nonlinear analysis method. A note on the windowing method used is also given.

A) Median Frequency and Kurtosis

The MDF [4] is obtained from the power spectrum by finding the frequency for which the power below the frequency is equal to half the total power. The MDF is not affected by the data distribution, but is sensitive to time domain correlation. The Kurtosis is a basic high order statistic (order 4.) It is not directly affected by time domain correlations, but is sensitive to non-normal distribution and especially to extreme values. The MDF and Kurtosis can together represent a large spectrum of the simpler cause that affects nonlinear features.

B) Higuchi's Fractal Dimension

The Higuchi's FD method [11] calculates the slope of the average curve length with respect to the logarithm of the measurement scale. The arbitrary parameters of the method consists of the measurement steps, which can be seen as subsampling ratios. In this paper, these were selected from 1 to 19 at interval of 4. The FD is used here both as a comparison method as well as the drive of the SA presented next.

C) Surrogate Analysis

The SA method [7] compares the FD of the original data to a sampling of the distribution of the FD of surrogate series. The surrogate series were created by the Fast Fourier Transform (FFT) method. The FFT is applied, the phase is uniformly randomized and returned in the time domain by mean of the inverse Fast Fourier Transform (IFFT.) This standard process is shown in fig. 1 (a). The original series FD is compared to a certain number of surrogate series FD. The null hypothesis that the FD of the original series could be obtained by a linear stochastic process (ARMA) is rejected if it is outside the range of the surrogates FDs. The SA is generally considered to assess that a nonlinear feature measured is caused in fact by an underlying nonlinear process and not simply an ARMA process [5]. However, a lot of information is lost by using a discrete output. It is therefore interesting to study its impact on a continuous valued version of the SA, as proposed in [12]. In this approach, the difference between the original series FD D and the mean of the FD of the surrogate series D_s normalised by the standard deviations gives the Z score:

$$Z = \frac{D - \bar{D}_s}{\text{std}(D_s)} \quad (1)$$

A schematic of this version of the SA is provided in fig. 1 (b). This score is analogous to the p-value of a t-test. In this paper, the number of 200 surrogate series are generated for the continuous version.

D) Windowing

A windowing method is used to reduce the periodic extension discontinuity artifacts associated with the FFT. The Tukey window [13] is used with a shape parameter of 0.02. The window was applied to the original and surrogate series. It was also used for the MDF and FD calculations for comparison purpose.

3. EMG COLLINEAR BIPHASIC MODEL

This section presents the model used for generating the signals with emphasis with the synchronization of the action potentials. Geometric considerations are reduce to a minimum in order to focus the attention on the time domain aspects. The model for the single synchronized impulse is described, followed by the modification of the model for synchronized impulse train.

A) Single Synchronized Impulse

The EMG model used is a very simple one. It uses a biphasic action potential model, as described in [14]. The individual fibers are considered as infinite lines. It also assumes that the different fibers are collinear. The biphasic action potential model is composed of a current source and a current sink producing a potential field φ , as shown in fig. 1 (from [14]):

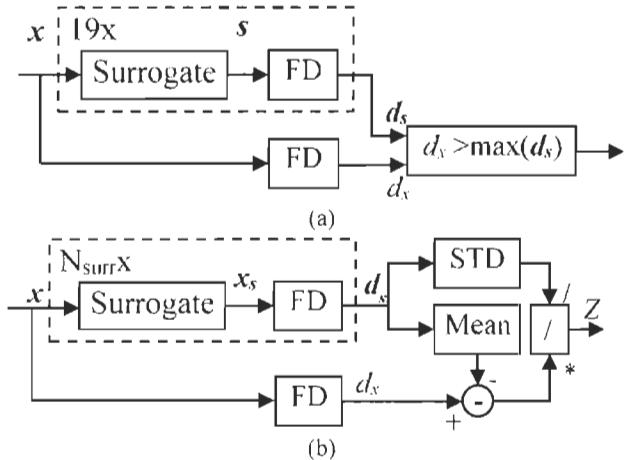


Fig. 1 Schematic of a standard right-sided SA test (a) yielding a discrete (true/false) result. Continuous result version of the SA test (b), giving a score Z .

$$\varphi(x, y) = \frac{1}{4\pi\nu} \left(\frac{1}{r_1} - \frac{1}{r_2} \right) \quad (2)$$

where x is the sensor position in the fiber direction, y is the sensor distance to the fiber, $r_n = \sqrt{x^2 + y^2}$ and ν is the medium conductivity. The factor $1/4\pi\nu$ can be considered constant and ignored in the model. The CV σ must however been taken into account for the propagation of the action potential. A time of arrival Δt is included to study the synchronisation. By setting the distance between the sink and source equal to $2b$, ignoring the factor and including the propagation, the potential becomes:

$$\varphi_n(x, y, t) = \frac{1}{\sqrt{(x+b-\sigma(t-\Delta t_n))^2 + y^2}} - \frac{1}{\sqrt{(x-b-\sigma(t-\Delta t_n))^2 + y^2}} \quad (3)$$

This basic biphasic action potential is combined either synchronously or non-synchronously. In both case, the signal is composed of a sum of biphasic action potential with varying time of arrival. With x and y kept constant (x can even be set at 0), the multiple fibers action potential is,

$$\psi(t) = \sum_{n=1}^{N_{fibers}} \varphi_n(x, y, t) \quad (4)$$

The difference between the synchronised ψ_s and non-synchronised ψ_{ns} versions of the multiple fibers action potentials lies in the distribution of the time of arrival Δt . For the synchronised version, a random Gaussian distribution, centered at the center of the time window is used, with a very small standard deviation σ_{sync} . For perfect synchronisation, this standard deviation is null. For the non-synchronised version, a random uniform distribution is used. To reduce the border effects, the span of the uniform distribution is slightly larger than the time window.

The number of fibers N_{fibers} used for non-synchronised signal affects greatly the validity of the ARMA null-hypothesis, especially when it is low. At the limit, when $N_{fibers} = 1$, the resulting signal is equivalent to a perfectly synchronized signal. The number of fibers is less critical for the synchronised signal.

The synchronization ratio is defined as the power ratio of the synchronized signal to the non-synchronized signals. The fact that a randomly generated non-synchronized signal can, by

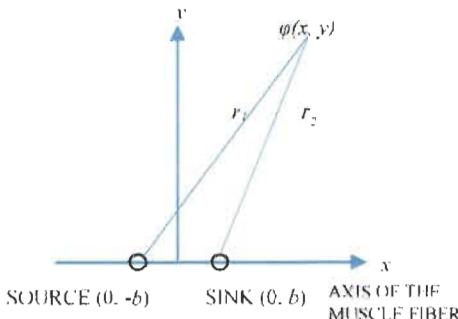


Fig. 2 Dipole model representation. Reproduced from [14].

chance, somehow exhibit synchronisation is ignored, as well as the desynchronizing effect of the standard deviation of the synchronised signal σ_{sync} . The most realistic way to produce a signal of a certain synchronization ratio would be to vary the number of fibers of the synchronized and non-synchronized parts. However, as the number of action potential can affect the nonlinear characteristics, a synchronization ratio scaling parameter (γ) approach is rather chosen:

$$\psi_\gamma = \sqrt{\gamma}\psi_s + \psi_{ns} \quad (5)$$

The signals ψ_s and ψ_{ns} are normalized before the scaling. The sum ψ_γ does not need to be normalized, since the different features used in this paper are invariant to scaling.

B) Synchronized Impulse Train Model

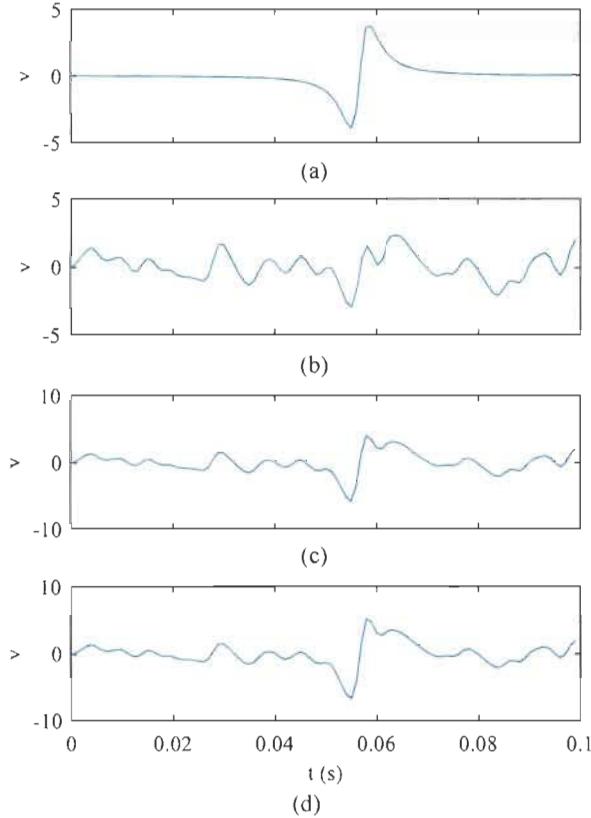


Fig. 3 Example of simulated sEMG signals with a CV of 4 m/s and a **synchronized impulse train of length 1**. In (a), a synchronized signal is shown. In (b), no synchronization is present. The signals in (c) and (d) are linear combination of (a) and (b) for synchronization ratios of 0.5 and 1 respectively.

The model used for the impulse train is similar to the one described previously. The impulse train ψ_t is generated by replicating L_{train} times the synchronized signal ψ_s at a regular interval τ . A variability of this interval is added, modeled as a variable $\Delta\tau$ with normal distribution of standard deviation σ_τ :

$$\psi_t = \sum_{l=1}^{L_{train}} \psi_s(t - \tau - \Delta\tau_l) \quad (6)$$

The time windows becomes larger as the train becomes longer. In this paper, the number of fibers for the non-synchronized signal is scaled by the length of the impulse train when its length vary. Because the fibers are considered collinear, this is equivalent to a fiber that fires multiple times (with overlapping action potential allowed.) As previously the scaling approach is used for combining the normalized synchronized and non-synchronized signals:

$$\psi_\gamma = \sqrt{\gamma}\psi_t + \psi_{ns} \quad (7)$$

Examples of the different signals involved are given in fig. 3 for a length 1 synchronized impulse train and in fig. 4 for a length 10 synchronized impulse train for a CV of 4 m/s. The other parameters are given in the next section.

4. SIMULATIONS

This section shows the numerical experiments realized to highlight the properties of the SA with regard to the

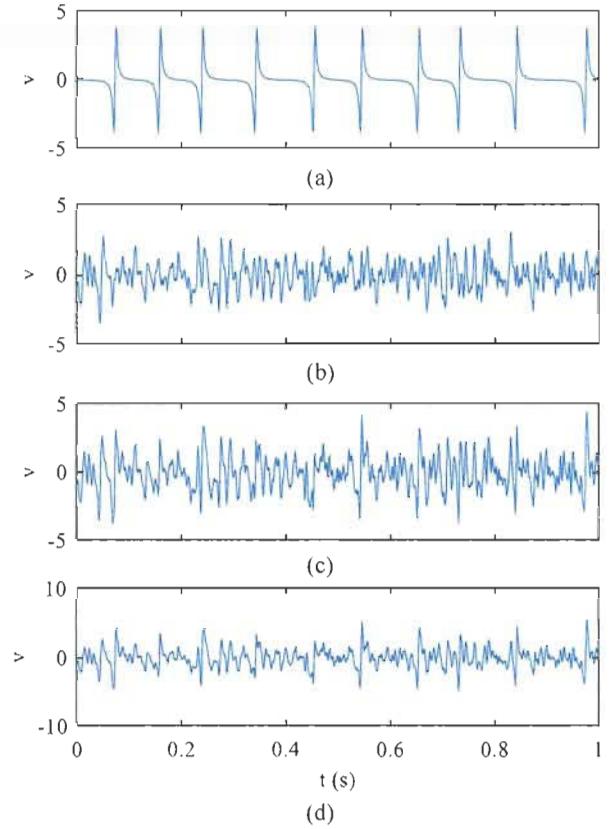


Fig. 4 Example of simulated sEMG signals with a CV of 4 m/s and a **synchronized impulse train of length 10**. In (a), a synchronized signal is shown. In (b), no synchronization is present. The signals in (c) and (d) are linear combination of (a) and (b) for synchronization ratios of 0.5 and 1 respectively.

Table I: Constant parameter through all simulations

Sampling Frequency	f_{samp}	1 kHz
Muscle Fibre to Sensor Distance	y	1 cm
Source/Sink Distance	b	0.025 cm
Synchronous Pulses Time Stdev	σ_{sync}	0.01 s
Inter Pulse Stdev	σ_t	1e-4 s
N Impulse Signals not Synchronized	N_{fibers}	100
N Impulse Signals Synchronized	N_{fibers}	100

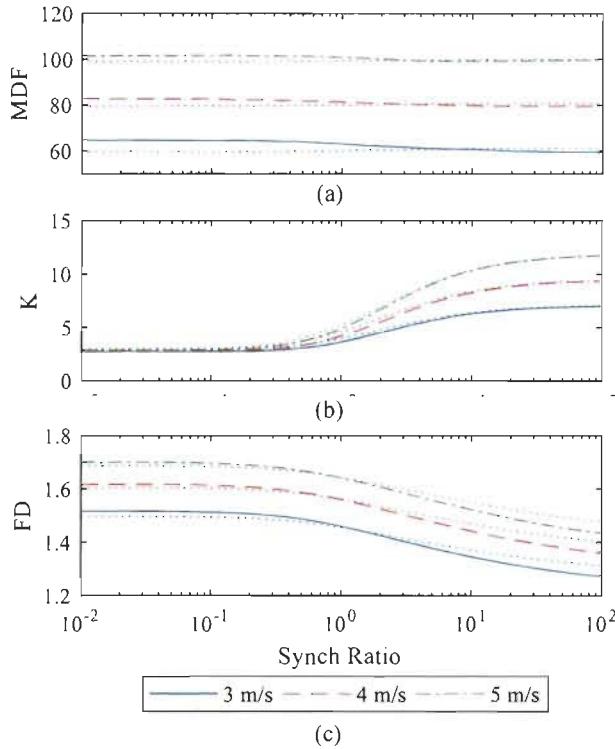


Fig. 5 Basic features vs synchronization ratio for different CV. The line styles given in the legend are for a synchronized impulse train length of 1 while the dotted lines have a length of 10. The MDF (a), Kurtosis (b) and FD (c) are shown. 1000 Monte Carlo iterations are used for each point.

synchronization ratio, synchronized impulse train length and CV in comparison to the other features.

A) General parameters

Although the model used is quite simple, some parameters were set constant throughout all simulations to simplify the comparison. An overview of the simulation parameter is given in Table I.

B) Simulation results of basic features

The MDF, Kurtosis and FD's synchronization ratio impact are shown in fig. 5. The mean value over 1000 Monte Carlo simulations is presented. The signals used have a train length of 1 and 10.

Although the MDF varies with the SR, it is most likely due to windowing effect. There is much more windowing effect for unsynchronized. Also, the longer the train, the lower the windowing problem. This can explain why long train results are almost flat. However, if the MDF is not sensitive to

synchronization, it is strongly dependant on conduction velocity.

The Kurtosis varies with synchronization. This variability is stronger as the CV is increased. When no synchronization is present, the CV does not affect the Kurtosis. Hence, the CV can be seen as a multiplicative factor of the effect of the synchronization. The mean of the Kurtosis is not affected by the train length.

The FD is modified by the CV and synchronization independently. The mean of the FD is only slightly affected by the train length.

The effect of the standard deviation of the train length on the basic features are discussed in the sensitivity analysis section.

C) Simulation results for the Surrogate Analysis

The effect of the synchronization ratio and the CV on the SA are shown for the discrete version of the SA in fig. 6 and the continuous version in fig. 7

The results for train lengths of 1 and 10 are shown. It is clear that as in the Kurtosis case, a multiplicative effect between the CV and the SA relation to synchronization ratio is present. However, this relation is even stronger when the train length increases. Residual windowing problems still can be seen for the single impulse version, especially at low CV.

The train length effect is targeted in the results presented in fig. 8. Again as for the CV, some kind of multiplicative effect is seen, this time between the train length and the synchronization effect on the mean SA result.

D) Sensitivity Analysis

The sensitivity operator S with respect to the synchronization of a feature f is defined as the derivative of the mean of the feature with respect to the synchronization divided by the standard deviation of the feature:

$$S\{f\}(\gamma) = \frac{1}{\text{std}(f)} \frac{df}{d\gamma}. \quad (8)$$

In this paper the derivative calculated by using the forward difference between two simulated points. The sensitivity was not sampled at regular steps, but were the same for every feature tested.

The fig. 9 shows the sensitivity of the SA for different synchronized train length. It is clear that for longer impulse train the sensitivity becomes greater. Also, the sensitivity is at its peak when the synchronization ratio is around 0.3.

The fig. 10 shows the sensitivity of the four features for a train of length 10. In a large range, the SA has the highest sensitivity. The sensitivity of the MDF is most likely due to border effects. For a synchronization ration of 0.1, the SA sensitivity of the SA (7.8) is twice larger than the sensitivity of the Kurtosis (3.5), the second most sensitive feature.

E) Correlation between the features residuals

A correlation matrix of the different features residuals was studied in order to explore the possibility of using multiple features to increase the sensitivity. The less correlation, the more likely it is possible to combine the different features. A single example is given in Table 2 for a CV of 4 m/s, a synchronization ratio γ of 1 and a train length L of 1. The correlation matrix was built with 30000 Monte Carlo iterations. A bootstrap method was used to assess the

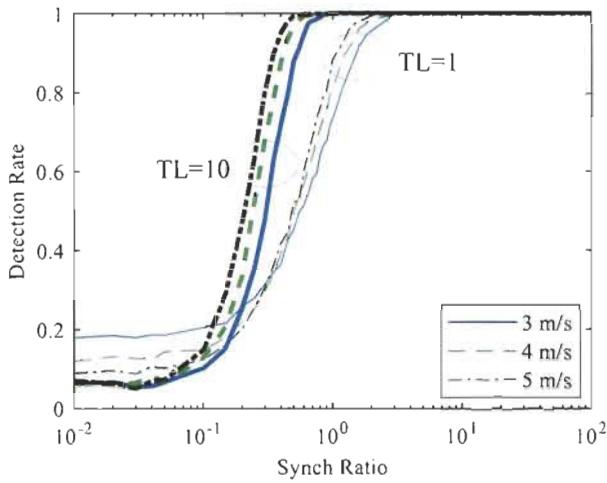


Fig. 6 Detection rate of the discrete version of the SA vs the synchronization ratio at different CV. The thin lines are for synchronized impulse train length of 1 and thick lines for impulse train length of 10.

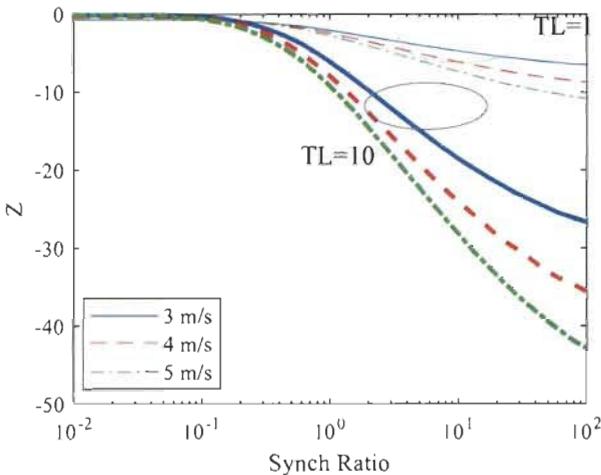


Fig. 7 Z score of the continuous version of the SA vs synchronization ratio for different CV. The thin lines are for synchronized impulse train length of 1 and thick lines for impulse train length of 10.

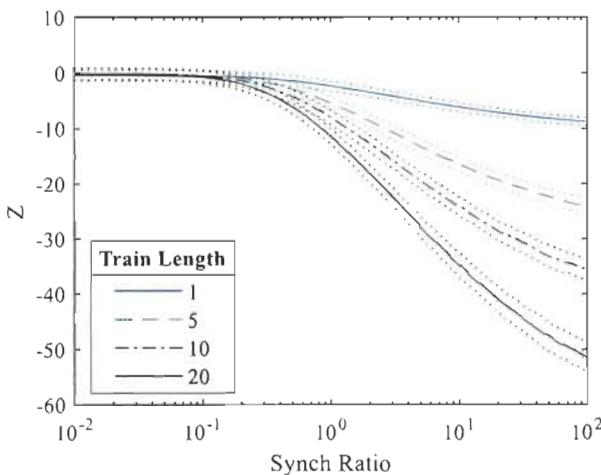


Fig. 8 Z score of the continuous version of the SA vs synchronization ratio at a CV of 4 m/s for different synchronized impulse train length. The dotted lines shows the ± 1 standard deviation limits.

precision of the correlation matrix elements. With 10000 bootstrap resampling iterations, the maximum standard deviation of the element of the correlation matrix was 0.0061. The results obtained, with a maximum correlation of 0.44 between the FD and SA shows that there is a possible gain to use multiple features together. It is noteworthy that such correlation matrix is different when varying the simulation parameters.

5. DISCUSSION

The first use of the findings of this paper is to add a possible interpretation of the SA applied to signals that can involve a synchronization similar to the EMG case. The CV effect does not change the interpretation of the SA but make it more sensitive to the synchronization. However, from the SA alone, it is not possible to distinguish between synchronization and other already existing explanation of the SA positive results such as real underlying nonlinear behaviour or time-varying phenomenon [15]. This aspect presented in this paper would be still valid on more realistic models.

A second use of the SA/synchronization/CV relationship is in the estimation of the synchronization and CV. However, since this inverse problem has not been tackled here, it has not been shown in this paper if the use of SA allows better estimation. It has been showed that the SA residuals are not strongly correlated to the other features residuals. It is not clear however if the SA contains more information than a group of simpler features. If the SA contains effectively different information than simpler method, the inverse problem would be the most interesting application of this paper.

But, the first question that arises is the performance of the SA in relation to the EMG model. There is probably an effect between the distance and synchronization similar to the relation between the CV. The real question however is the impact of having different fibers at different distance, and possibly with different CV. For this situation, even the notion of synchronization should be redefined. Test should hence been made on gradually more realistic models [10][16].

A sensitivity analysis to common interference signal such as Power Line Interference (PLI) and electrocardiogram (ECG) should also be performed. An optimisation of the windowing method and size should also be made. The effect of white noise, which can have a large impact on nonlinear features [17] should be investigated with regards to the sensitivity of the SA to synchronization and CV.

If the information about the synchronization ratio is able to help for classification purpose, the use of SA is appropriate for feature extraction. Without recovering the exact synchronization ratio and CV, the feature can be used in a similar manner as was presented in [12].

Lastly, no optimization of the non-linear feature has been made to maximize the sensitivity of the FD and the SA to the CV and synchronization. Also, other nonlinear feature could be considered. A group of nonlinear features, with different parameters and their SA could be used to identify the parameters of complex models.

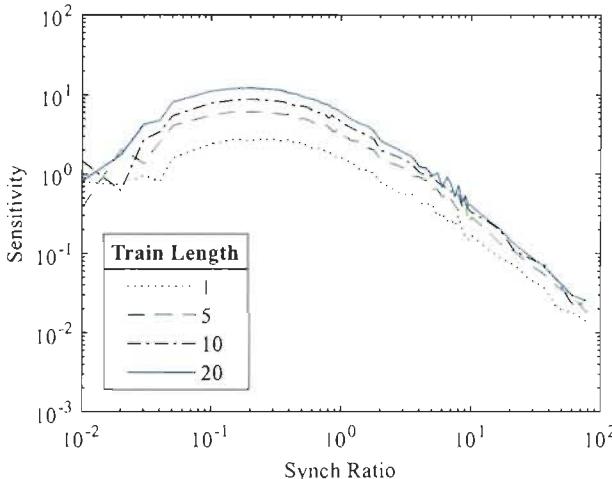


Fig. 9 Sensitivity of the SA with respect to the synchronization ratio for different synchronized train length.

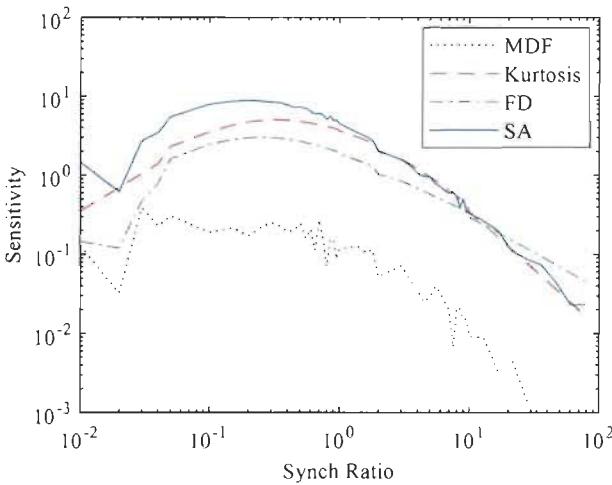


Fig. 10 Sensitivity of the SA with respect to the synchronization ratio for different features at a synchronized train length of 10.

Table 2: Correlation between features residuals for train length of 1, CV = 4 and SR = 1, for 10000 Monte Carlo iterations.

Features	MDF	Kurtosis	FD	Z SA
MDF	1.0000	-0.0265	0.6674	0.0557
Kurtosis	-0.0265	1.0000	-0.0230	-0.1372
FD	0.6674	-0.0230	1.0000	0.4405
Z SA	0.0557	-0.1372	0.4405	1.0000

From this discussion, it can be seen that although the model used here was far from realistic, the parameters used in the SA were far from optimal. It is expected that as the SA is optimized and joint with multiple features, it could have the power of identifying the parameters of more complex models.

6. CONCLUSION

This paper showed a new interpretation of the SA: the synchronisation of the MUAPs. The model used was chosen in order to lead to an obvious interpretation of the results. In more complex scenarios, the interpretation of the SA will not be so clear. However, when the SA is used to analyse any action potential type signals, the synchronisation should generally be considered. This paper showed also that the SA is an interesting candidate for the estimation of motor unit

characteristics such as the synchronisation and CV. Probably, other higher level characteristics like muscular fatigue, which is linked to synchronisation and CV could be approached in the same way by the SA. The remaining question is to find the part of the information contained in the SA which is not already present in linear and classical nonlinear features, or rather can the SA can be combined to the MDF and FD to obtain better resolution in the joint estimation of the synchronisation and CV.

REFERENCES

- [1] B. Bigland-Ritchie, E. Donovan and C. Roussos, "Conduction velocity and EMG power spectrum changes in fatigue of sustained maximal efforts", *Journal of Applied Physiology*, vol. 51, no. 5, pp. 1300-1305, 1981.
- [2] M. González-Izal, A. Malanda, E. Gorostiaga, M. Izquierdo, "Electromyographic models to assess muscle fatigue," *Journal of Electromyography and Kinesiology*, vol. 22, no 4, pp. 501-512, 2012.
- [3] D. Farina, L. Fattorini, F. Felici and G. Filligoi, "Nonlinear surface EMG analysis to detect changes of motor unit conduction velocity and synchronization", *Journal of Applied Physiology*, vol. 93, no. 5, pp. 1753-1763, 2002.
- [4] L. Fattorini, F. Felici, G. Filligoi, M. Trabalesi and D. Farina, "Influence of high motor unit synchronization levels on non-linear and spectral variables of the surface EMG", *Journal of Neuroscience Methods*, vol. 143, no. 2, pp. 133-139, 2005.
- [5] P. Padmanabhan and S. Puthusserypady, "Nonlinear analysis of EMG signals—A chaotic approach," in Proc. IEEE Annu. Int. Conf. IEEE Eng. Med. Biol., Sep. 2004, vol. 1, pp. 608–611.
- [6] B. Bigland-Ritchie, E. Donovan and C. Roussos, "Conduction velocity and EMG power spectrum changes in fatigue of sustained maximal efforts", *Journal of Applied Physiology*, vol. 51, no. 5, pp. 1300-1305, 1981.
- [7] J. Theiler, S. Eubank, A. Longtin, B. Galdrikian, J. D. Farmer, "Testing for nonlinearity in time series: the method of surrogate data," *Physica D: Nonlinear Phenomena*, 58(1-4), 77-94, 1992.
- [8] J. Timmer, "What Can Be Inferred from Surrogate Data Testing?", *Physical Review Letters*, vol. 85, no. 12, pp. 2647–2647, 2000.
- [9] M. Lei, Wang, Z. Feng, "Detecting nonlinearity of action surface EMG signal," *Physics Letters*, 290(S), pp. 297-303, 2001.
- [10] P. Farina, D., Mesin, L., Martina, S., & Merletti, R. (2004). A surface EMG generation model with multilayer cylindrical description of the volume conductor. *IEEE Transactions on Biomedical Engineering*, 51(3), 415-426.
- [11] T. Higuchi, "Approach to an irregular time series on the basis of the fractal theory", *Physica D: Nonlinear Phenomena*, vol. 31, no. 2, pp. 277-283, 1988.
- [12] M. Caza-Szoka, D. Massicotte, F. Nougarou, and M. Descarreaux, "Surrogate analysis of fractal dimensions from SEMG sensor array as a predictor of chronic low back pain," 2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), 2016.
- [13] D. Stoffer and P. Bloomfield, "Fourier Analysis of Time Series: An Introduction", *Journal of the American Statistical Association*, vol. 95, no. 452, p. 1373, 2000.
- [14] D. Boyd, P. Lawrence and P. Bratty, "On Modeling the Single Motor Unit Action Potential", *IEEE Transactions on Biomedical Engineering*, vol. -25, no. 3, pp. 236-243, 1978.
- [15] J. Timmer, "Power of surrogate data testing with respect to nonstationarity," *Physical Review E*, vol. 58, no. 4, pp. 5153–5156, Jan. 1998.
- [16] Q. Farina, D., & Negro, F. (2015). Common synaptic input to motor neurons, motor unit synchronization, and force control. *Exercise and sport sciences reviews*, 43(1), 23-33.
- [17] D. Kugiumtzis, "On the Reliability of the Surrogate Data Test for Nonlinearity in the Analysis Of Noisy Time Series", *International Journal of Bifurcation and Chaos*, vol. 11, no. 07, pp. 1881-1896. 2001.