## UNIVERSITÉ DU QUÉBEC

### MÉMOIRE PRÉSENTÉ À L'UNIVERSITÉ DU QUÉBEC À TROIS-RIVIÈRES

### COMME EXIGENCE PARTIELLE DE LA MAÎTRISE EN MATHÉMATIQUES ET INFORMATIQUE APPLIQUÉES

PAR

MÉLINA MAILHOT

### PUISSANCES ASYMPTOTIQUES ET À TAILLES FINIES DE TESTS DE NORMALITÉ SOUS DES ALTERNATIVES LOCALES

NOVEMBRE 2009

Mélina Mailhot, 2009

### Université du Québec à Trois-Rivières

Service de la bibliothèque

### <u>Avertissement</u>

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.

# REMERCIEMENTS

Premièrement, je tiens à remercier sincèrement mon directeur de recherche, M. Jean-François Quessy, professeur au Département de mathématiques et d'informatique de l'Université du Québec à Trois-Rivières. Il m'a permis d'explorer la statistique à travers un sujet fort intéressant qui a su combiner nos intérêts scientifiques respectifs. Il a su guider mes travaux par ses remarques pertinentes, en plus de m'encourager et me soutenir durant toutes les étapes de réalisation de ce mémoire. La confiance qu'il m'a accordée, ainsi que sa grande disponibilité, ont contribué à la réussite de ma maîtrise. Sa capacité à susciter la motivation des étudiants fut exemplaire pour moi.

Je suis également reconnaissante envers Alain Desgagné, professeur au Département de mathématiques de l'Université du Québec à Montréal. J'ai grandement apprécié travailler avec lui au début de ma formation à la maîtrise, ce qui m'a permis de bénéficier de ses judicieux conseils. Il m'a accordé beaucoup de temps et m'a appris beaucoup en statistique et en actuariat. Il m'a également beaucoup motivé afin que je complète mes études à la maîtrise.

De plus, je désire souligner les encouragements constants des membres de ma famille tout au long de mes études. J'en profite aussi pour remercier mes amis, qui m'ont toujours supportée et permis de me divertir même dans les moments les plus difficiles.

#### REMERCIEMENTS

Un remerciement spécial va à mon amoureux, Fabien Girard. Il m'a beaucoup encouragée, soutenue et conseillée. Sa présence a contribué à élaborer un mémoire dont je suis très fière.

Également, je souhaite remercier Mhamed Mesfioui et Sébastien Tremblay, professeurs au *département de mathématiques et d'informatique appliquées* de l'UQTR, pour avoir accepté de lire et d'évaluer mon mémoire. Les commentaires qu'ils m'ont transmis ont permis d'améliorer la version finale.

Une partie des travaux de ce mémoire a été financée par des octrois individuels accordés à M. Jean-François Quessy par le *Conseil de Recherche en Sciences Naturelles et en Génie* du Canada, ainsi que par le *Fonds Québécois de Recherche sur la Nature et les Technologies.* Je remercie également l'*Institut des Sciences Mathématiques du Québec* pour les bourses d'études qu'il m'a accordées tout au long de ma maîtrise.

# AVANT-PROPOS ET STRUCTURE DU MÉMOIRE

Ce mémoire de maîtrise est composé de six chapitres. Les cinq premiers sont rédigés en français. Le chapitre 6 comprend l'intégral d'un article scientifique soumis à la revue *Journal of Statistical Planning and Inference*.

Ma contribution principale à ce mémoire se situe au niveau des cinq premiers chapitres. Ceux-ci donnent une introduction au problème de l'adéquation à la distribution normale ainsi qu'une revue de littérature assez complète sur les tests existants. J'ai également conçu et mis en œuvre un plan de simulation pour évaluer la puissance de plusieurs de ces tests.

Spécifiquement, le chapitre 1 introduit le lecteur à la problématique des tests de normalité. On y présente le problème de l'adéquation à la distribution normale et quelques-unes des caractéristiques les plus importantes de cette loi. Dans les chapitres 2, 3 et 4, trois catégories populaires de tests de normalité sont abordées. Il s'agit respectivement des tests basés sur les moments, des tests basés sur la fonction de répartition et les tests de régression et d'entropie. Le chapitre 5 est dévolu à l'évaluation de la puissance à tailles finies de plusieurs tests présentés aux chapitres 2, 3 et 4. Cette étude de puissance se distingue des nombreuses autres offertes dans la littérature par la considération d'alternatives locales. Le chapitre 6, constitué d'un article soumis, est en quelque sorte une extension aux cinq premiers chapitres. En effet, au lieu de s'intéresser à la puissance des tests pour des tailles échantillonales finies, l'efficacité asymptotique est considérée. Cela nécessite l'obtention de la loi limite des statistiques de test sous des types particuliers de contre-hypothèses, à savoir des alternatives contiguës. Pour constituer l'article, quelques éléments de ma revue de littérature et de mon étude de simulation ont été repris. Cependant, les résultats asymptotiques, qui constituent le cœur de l'article, sont redevables à mon directeur de recherche, Jean-François Quessy.

La réalisation de l'étude de puissance ainsi que les approximations des courbes de puissance locale ont nécessité de la programmation. Celle-ci a été effectuée à l'aide de MATLAB. L'intégralité des codes informatiques utilisés se retrouve à l'annexe A.

# Table des matières

Remer	ciements	ii
Avant-	propos et structure du mémoire	iv
Liste d	les tableaux	x
Liste d	les figures	xii
Chapit	re 1. Introduction	1
Chapit	are 2. Tests basés sur des moments	6
2.1	Coefficients d'asymétrie et d'aplatissement	7
2.2	Test basé sur le coefficient d'asymétrie	12
2.3	Test basé sur le coefficient d'aplatissement $\ldots$	12
2.4	Test de Jarque-Bera	13
2.5	Version robuste du test de Jarque-Bera	13
2.6	Test de Gel et al. (2007)	14
Chapit	re 3. Tests basés sur la fonction de répartition	15
3.1	Processus empiriques pour l'adéquation	15
3.2	Le test de Cramér-von Mises	18
3.3	Le test de Anderson-Darling	19
3.4	Le test de Kolmogorov-Smirnov	20

-

Chapitre 4. Autres tests 21			
4.1	Tests de régression		21
	4.1.1	Idée générale	21
	4.1.2	Test de Shapiro-Wilk	22
	4.1.3	Test de D'Agostino	23
4.2	Test b	basé sur l'entropie d'une loi de probabilité	24
	4.2.1	Notion d'entropie	24
	4.2.2	Test de Vasicek	25
Chapi	tre 5. i	Évaluation de la puissance pour des tailles finies	<b>27</b>
5.1	Alterr	natives locales à la loi normale	27
	5.1.1	Mélanges de lois normales	27
	5.1.2	Alternative à queues lourdes	29
	5.1.3	Une alternative asymétrique	30
5.2	Résult	tats des simulations	31
	5.2.1	Puissance sous des mélanges de lois normales	32
	5.2.2	Puissance sous l'alternative à queues lourdes	35
	5.2.3	Puissance sous une alternative asymétrique	40
Chapi	tre 6	Asymptotic power of tests of normality under local	
alt	ernativ	es	43
6.1	Introd	luction	43
6.2	Test s	tatistics for non-normality	46
	6.2.1	Tests based on sample skewness and kurtosis	46
	6.2.2	The test of Gel et al. (2007) $\ldots \ldots \ldots \ldots \ldots$	48
	6.2.3	Functionals of an empirical goodness-of-fit process	48
6.3	Asym	ptotic behavior of the test statistics under local sequences	52

6.4	Three	e kinds of local alternatives	57
6.5	Asym	ptotic power and efficiency	61
6.6	Invest	tigation of the asymptotic efficiency of the seven tests	66
	6.6.1	Local power curves	66
	6.6.2	Relative efficiency	69
6.7	Discu	ssion and link with empirical results	73
Conclu	ision		78
Annex	e A. F	rogrammes en Matlab	80
A.1	Calcul	des statistiques de test	80
	A.1.1	Statistique $S_n$	80
	A.1.2	Statistique $K_n$	81
	A.1.3	Statistique $JB_n$	82
	A.1.4	Statistique $R_n$	83
	A.1.5	Statistique $\text{CVM}_n$	84
	A.1.6	Statistique $AD_n$	85
	A.1.7	Statistique $\mathrm{KS}_n$	86
A.2	Progra	mmes de simulation selon des alternatives locales	87
	A.2.1	Mélanges de lois normales	87
	A.2.2	Mélanges de lois normale et Student	88
	A.2.3	Alternative asymétrique	89
A.3	Estima	ation des valeurs critiques	90
A.4	Calcul	s de puissance	91
	A.4.1	Puissance à tailles finies sous des mélanges de normales .	91
	A.4.2	Puissance à tailles finies sous des mélanges de normale	
		et Student	92

Table des matières	ix
A.4.3 Puissance à tailles finies sous l'alternative asymétrie	que . 93
A.4.4 Courbes de puissance locale	94
Références	95

# LISTE DES TABLEAUX

5.1	Estimation, basée sur 10 000 répétitions, de la puissance de	
	$S_n, K_n, JB_n, R_n, CVM_n, AD_n$ et $KS_n$ sous l'alternative (5.1)	
	avec $\nu = 1$ et $\gamma = 1$	34
5.2	Estimation, basée sur 10 000 répétitions, de la puissance de	
	$S_n, K_n, JB_n, R_n, CVM_n, AD_n$ et $KS_n$ sous l'alternative (5.2)	
	avec $\nu = 5$	36
5.3	Estimation, basée sur 10 000 répétitions, de la puissance de	
	$S_n, K_n, JB_n, R_n, CVM_n, AD_n$ et $KS_n$ sous l'alternative (5.2)	
	avec $\nu = 10$	37
5.4	Estimation, basée sur 10 000 répétitions, de la puissance de	
	$S_n, K_n, JB_n, R_n, CVM_n, AD_n$ et $KS_n$ sous l'alternative (5.2)	
	avec $\nu = 20$	38
5.5	Estimation, basée sur 10 000 répétitions, de la puissance de	
	$S_n, K_n, JB_n, R_n, CVM_n, AD_n \text{ et } KS_n \text{ sous l'alternative } (5.2)$	
	avec $\nu = 30$	39
5.6	Estimation, basée sur 10 000 répétitions, de la puissance de	
	$\mathbf{S}_n,\mathbf{K}_n,\mathbf{JB}_n,\mathbf{R}_n,\mathbf{CVM}_n,\mathbf{AD}_n$ et $\mathbf{KS}_n$ sous l'alternative (5.3) .	42
6.1	Estimation, based on $100\ 000$ replicates, of the 95-th percentile	
	of the distribution of $S_n$ , $K_n$ , $JB_n$ , $R_n$ , $CVM_n$ , $AD_n$ and $KS_n$	
	under the normality assumption	51
6.2	Asymptotic relative efficiency of $S_n$ , $K_n$ , $R_n$ , $CVM_n$ , $AD_n$ and	
	$\mathrm{KS}_n$ with respect to the Jarque-Bera test statistic $\mathrm{JB}_n$	73

6.3	Estimation, based on 10 000 replicates, of the power of $S_n$ , $K_n$ ,	
	$JB_n$ , $R_n$ , $CVM_n$ , $AD_n$ and $KS_n$ under alternatives of the form	
	$\ell_{\delta}(z) = (1-\delta)\phi(z) + \delta h(z); n = 50 \dots \dots \dots \dots \dots \dots \dots$	75

# LISTE DES FIGURES

1.1	Histogramme de 2 500 observations
1.2	Densités normales d'écart-type $\sigma=1$ et de moyennes $\mu=0,1,2-3$
1.3	Densités normales de moyenne $\mu=0$ et d'écart-types $\sigma=1,2,3-4$
2.1	Densités asymétriques à gauche $(\beta_1 < 0)$ et à droite $(\beta_1 > 0)$ . $7$
2.2	Densités aplatie (figure de gauche) et gonflée (figure de droite) 8
4.1	Entropie de la densité normale en fonction de l'écart-type $\sigma$ . 25
5.1	Mélanges de lois $\mathcal{N}(0,1)$ et $\mathcal{N}(\nu,1)$ pour différentes valeurs de
	$\delta$ . À gauche, $\nu = 1$ ; à droite, $\nu = 2$
5.2	Mélanges de lois $\mathcal{N}(0,1)$ et $\mathcal{N}(0,4)$ pour différentes valeurs de $\delta$ 29
5.3	Alternative à que ues lourdes lorsque $g$ est la densité de Stu-
	dent. À gauche, $\nu = 5$ ; à droite, $\nu = 10$
5.4	Densités asymétriques avec diverses valeurs de $\delta$
5.5	Coefficients d'asymétrie (en haut) et d'aplatissement (en bas)
	en fonction de $\delta$ dans le modèle (5.1) quand $\nu=1$ et $\gamma=1$ 33
5.6	Coefficients d'asymétrie (en haut) et d'aplatissement (en bas)
	en fonction de $\delta$ dans le modèle (5.3) $\hdots$ 41
6.1	Local power curves of $S_n$ , $K_n$ , $JB_n$ , $R_n$ , $CVM_n$ , $AD_n$ and $KS_n$
	under model $\mathcal{A}_1$ . Left panel : $\mu = 1$ ; right panel : $\mu = 2$ 67
6.2	Local power curves of $S_n$ , $K_n$ , $JB_n$ , $R_n$ , $CVM_n$ , $AD_n$ and $KS_n$
	under model $\mathcal{A}_2$ . Left panel : $\sigma = 1.5$ ; right panel : $\sigma = 2$ 68
6.3	Local power curves of $S_n$ , $K_n$ , $JB_n$ , $R_n$ , $CVM_n$ , $AD_n$ and $KS_n$
	under model $\mathcal{A}_3$ . Left panel : $\nu = 5$ ; right panel : $\nu = 10$ 69

6.4	Asymptotic efficiency of $S_n$ , $K_n$ , $JB_n$ and $R_n$ as a function of	
	$\mu$ in model $\mathcal{A}_1.$ Left panel : $\mu \in [0,1];$ right panel : $\mu \in [1,3]$ .	70
6.5	Asymptotic efficiency of $S_n$ , $K_n$ , $JB_n$ and $R_n$ as a function of	
	$\sigma \in [1,3]$ in model $\mathcal{A}_2$	71
6.6	Asymptotic efficiency of $S_n$ , $K_n$ , $JB_n$ and $R_n$ as a function of	
	$\nu \in [5, 15]$ in model $\mathcal{A}_3$	72

# CHAPITRE 1

## INTRODUCTION

Supposons que l'on observe un phénomène qui fait intervenir une variable aléatoire. Par exemple, la crue annuelle sur une certaine rivière, les montants de réclamation en rapport avec une certaine assurance ou l'âge moyen où les gens contractent une certaine maladie. Pour bien comprendre ce phénomène, une façon efficace consiste à considérer la répartition des valeurs observées. Spécifiquement, on considère l'histogramme de ces observations. Un tel outil, basé sur 2 500 observations, est présenté à la figure 1.1.

Une étape de compréhension supplémentaire consiste à ajuster un modèle théorique à la représentation empirique de l'histogramme. Pour le faire d'une façon formelle et rigoureuse, il s'agit d'employer un test d'adéquation. Spécifiquement, notons f la densité de probabilité inconnue d'une certaine population. On désire vérifier si la densité  $f_0$  fournit un bon modèle théorique pour f, c'est-à-dire s'il explique adéquatement ce qui a été observé. Pour ce faire, les hypothèses nulle et alternative à confronter sont  $\mathcal{H}_0$  : la densité fest de la forme  $f_0$  et  $\mathcal{H}_1$  : la densité f n'est pas de la forme  $f_0$ . La littérature statistique traitant de ce problème est très volumineuse.



Figure 1.1: Histogramme de 2 500 observations

Un problème d'adéquation qui a retenu particulièrement l'attention concerne la distribution normale. Cette loi de probabilité a en effet connu beaucoup de succès pour la représentation de nombreux phénomènes. Ceci s'explique probablement, en partie du moins, par le théorème de la limite centrale. Celui-ci indique qu'une somme de variables aléatoires dont les variances respectives existent se comporte, asymptotiquement, comme une variable aléatoire de loi normale. Ainsi, comme plusieurs phénomènes que l'on observe sont le résultat d'une sommation, cette distribution est souvent adéquate pour représenter la réalité. À titre d'exemples, on peut citer le nombre de cellules cancéreuses dans un organe ou le montant total des réclamations d'une assurance. La vérification formelle de la normalité est

#### 1. INTRODUCTION

donc un problème important.

La densité de la loi normale de moyenne  $\mu \in \mathbb{R}$  et d'écart-type  $\sigma > 0$  est

$$\phi_{\mu,\sigma}(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left\{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2\right\},$$

où  $x \in \mathbb{R}$ . Des exemples de cette densité sont donnés aux figures 1.2 et 1.3.



Figure 1.2: Densités normales d'écart-type  $\sigma = 1$  et de moyennes  $\mu = 0, 1, 2$ 

Une procédure d'adéquation à la famille de densités  $\{\phi_{\mu,\sigma}; \mu \in \mathbb{R}, \sigma > 0\}$ s'appelle un test de normalité. Si f dénote la densité inconnue d'une certaine population, il consiste à confronter les hypothèses

$$\mathcal{H}_0: f(x) = \phi_{\mu,\sigma}(x)$$
 et  $\mathcal{H}_1: f(x) \neq \phi_{\mu,\sigma}(x)$  pour au moins un  $x \in \mathbb{R}$ .

À noter qu'ici, les paramètres  $\mu$  et  $\sigma$  seront supposés inconnus. Les hypothèses  $\mathcal{H}_0$  et  $\mathcal{H}_1$  précédentes sont alors qualifiées de *composites*. Celles-ci sont donc beaucoup plus flexibles et réalistes que si on supposait des valeurs

#### 1. INTRODUCTION



Figure 1.3: Densités normales de moyenne  $\mu = 0$  et d'écart-types  $\sigma = 1, 2, 3$ 

 $\mu_0$  et  $\sigma_0$  aux paramètres, puisqu'en pratique ces quantités sont rarement connues. Ainsi, pour toutes les procédures qui seront décrites dans la suite, il faudra estimer  $\mu$  et  $\sigma^2$ . Leurs estimateurs naturels sont la moyenne et la variance empiriques, à savoir

$$\hat{\mu} = \frac{1}{n} \sum_{i=1}^{n} X_i$$
 et  $\hat{\sigma}^2 = \frac{1}{n-1} \sum_{i=1}^{n} (X_i - \hat{\mu})^2$ .

Les Chapitres 2, 3 et 4 constituent une revue de littérature assez exhaustive sur les tests de normalité. Une attention particulière sera portée aux procédures les plus populaires. De tels recensements se retrouvent, entre autres, dans les travaux de D'Agostino & Stephens (1986) et de Thode Jr. (2002). Dans la suite, on classera les tests de normalité en trois familles :

- (i) les tests basés sur les moments ;
- (ii) les tests basés sur la fonction de répartition ;
- (iii) les tests de régression et d'entropie.

#### 1. INTRODUCTION

Ces familles constitueront, respectivement, les chapitres 2, 3 et 4.

Afin de choisir un test adéquat parmi la panoplie de procédures disponibles, il convient de sélectionner le plus puissant. On rappelle que la puissance d'un test est sa capacité à rejeter l'hypothèse nulle lorsque celle-ci est fausse. Pour ce faire, on considérera dans ce mémoire des contre-hypothèses dites *locales*. Celles-ci permettent d'évaluer l'efficacité des tests sous de faibles écarts à  $\mathcal{H}_0$ .

Au Chapitre 5, la puissance de plusieurs procédures est évaluée à l'aide de simulations de type Monte-Carlo. Trois alternatives locales sont considérées. Ceci permet d'identifier les tests les plus puissants sous un scénario donné. Au Chapitre 6, qui contient l'intégral d'un article déjà soumis, l'idée de puissance locale est étendue au cas asymptotique, c'est-à-dire lorsque la taille d'échantillon est supposée infinie. Ceci amène à obtenir les lois asymptotiques des statistiques considérées. Cela permet de calculer leurs courbes de puissance asymptotiques locales. Ces dernières renseignent sur les procédures les plus efficaces sous de grandes tailles d'échantillons.

# CHAPITRE 2

# TESTS BASÉS SUR DES MOMENTS

Soit f, une certaine densité définie sur un domaine  $\mathcal{D} \subseteq \mathbb{R}$ . C'est donc dire que  $f(x) \ge 0$  pour tout  $x \in \mathcal{D}$  et

$$\int_{\mathcal{D}} f(x) \, \mathrm{d}x = 1.$$

Pour une variable aléatoire X dont la densité est f, son moment d'ordre k est défini par

$$\mathcal{E}(X^k) = \int_{\mathcal{D}} x^k f(x) \, \mathrm{d}x.$$

En particulier, le moment d'ordre 1 est la moyenne, c'est-à-dire que  $\mu = E(X)$ . Le moment centré d'ordre k de X est

$$\mu_k = \mathbf{E}\left\{ \left(X - \mu\right)^k \right\}.$$

Le moment centré d'ordre 2 est donc la variance de X.

Dans ce chapitre, on décrira des tests de normalité qui exploitent certaines caractéristiques des moments de la loi normale.

### 2.1 Coefficients d'asymétrie et d'aplatissement

Soit une variable aléatoire X de densité f, de moyenne  $\mu$  et de variance  $\sigma^2$ . Le coefficient d'asymétrie de f est défini par

$$\beta_1 = \mathbf{E}\left\{ \left(\frac{X-\mu}{\sigma}\right)^3 \right\}.$$
 (2.1)

Cet indice correspond au moment standardisé d'ordre trois, c'est-à-dire que  $\beta_1 = {\rm E}(Z^3), \, {\rm où}$ 

$$Z = \frac{X - \mu}{\sigma} \,. \tag{2.2}$$

Les valeurs possibles de  $\beta_1$  sont les réels. Quand  $\beta_1 > 0$ , on parle d'asymétrie positive. Ceci est la conséquence d'une densité dont la masse de probabilité est plus importante du côté des grandes valeurs de la distribution. De façon similaire,  $\beta_1 < 0$  indique une masse de probabilité plus importante pour les petites valeurs de la distribution. La figure 2.1 présente des distributions asymétriques à gauche et à droite.



Figure 2.1: Densités asymétriques à gauche  $(\beta_1<0)$  et à droite  $(\beta_1>0)$ 

Le coefficient d'aplatissement de f est le moment standardisé d'ordre quatre, c'est-à-dire

$$\beta_2 = \mathbf{E}\left\{ \left(\frac{X-\mu}{\sigma}\right)^4 \right\}.$$
 (2.3)

Les valeurs possibles de  $\beta_2$  sont les réels positifs. Quand cet indice est élevé, cela indique que les ailes de la distribution sont lourdes. À l'inverse, une faible valeur de  $\beta_2$  indique une distribution gonflée autour de sa moyenne.



Figure 2.2: Densités aplatie (figure de gauche) et gonflée (figure de droite)

Souvent, on juge de l'asymétrie et de l'aplatissement d'une distribution en rapport avec les valeurs obtenues pour la loi normale. Notons d'abord que si  $X \sim \mathcal{N}(\mu, \sigma^2)$ , alors sa forme centrée réduite (2.2) est de loi  $\mathcal{N}(0, 1)$ . On peut donc écrire

$$\beta_1 = \int_{-\infty}^{\infty} x^3 \phi_{0,1}(x) \,\mathrm{d}x.$$

Comme la fonction  $g(x) = x^3 \phi_{0,1}(x)$  est impaire, c'est-à-dire que  $g(-x) = (-x)^3 \phi_{0,1}(-x) = -x^3 \phi_{0,1}(x) = -g(x)$ , on déduit que  $\beta_1 = 0$ . Pour ce qui est du coefficient d'aplatissement, on note que

$$\beta_2 = \mathrm{E}(Z^4) = \mathrm{var}(Z^2) + \mathrm{E}^2(Z^2).$$

Par un résultat très connu,  $Z^2$  suit une loi khi-carré à 1 degré de liberté. Il s'ensuit que  $E(Z^2) = 1$  et var $(Z^2) = 2$ . Ainsi,  $\beta_2 = 2 + (1)^2 = 3$ .

Dans la suite, les coefficients d'asymétrie et d'aplatissement sont calculés pour les densités uniformes, Beta, exponentielle et double exponentielle. À noter qu'en développant les formules (2.1) et (2.3), on obtient

$$\beta_1 = \frac{\mathrm{E}(X^3) - 3\mu\mathrm{E}(X^2) + 2\mu^3}{\sigma^3}$$
(2.4)

et

$$\beta_2 = \frac{\mathrm{E}(X^4) - 4\mu \mathrm{E}(X^3) + 6\mu^2 \mathrm{E}(X^2) - 3\mu^4}{\sigma^4} \,. \tag{2.5}$$

**Exemple 2.1.** Soit une variable aléatoire distribuée uniformément sur l'intervalle (a,b). Dans ce cas, la densité est donnée par

$$f_{a,b}(x) = \frac{1}{b-a} \mathbb{I}_{[a,b]}(x),$$

où  $\mathbb{I}_A(x)$  est la fonction indicatrice d'un ensemble, c'est-à-dire

$$\mathbb{I}_{A}(x) = \begin{cases} 1, & si \ x \in A; \\ 0, & si \ x \notin A. \end{cases}$$

Pour une variable aléatoire X distribuée selon cette loi, on a

$$E(X^{j}) = \frac{b^{j+1} - a^{j+1}}{(j+1)(b-a)}.$$

On en déduit que

$$E(X) = \frac{b^2 - a^2}{2(b - a)}, \quad E(X^2) = \frac{b^3 - a^3}{3(b - a)},$$
$$E(X^3) = \frac{b^4 - a^4}{4(b - a)} \quad et \quad E(X^4) = \frac{b^5 - a^5}{5(b - a)}.$$

Par une application des formules (2.4) et (2.5), on trouve

$$\beta_1 = 0 \quad et \quad \beta_2 = -\frac{6}{5} \,.$$

Exemple 2.2. La densité Beta est de la forme

$$f_{a,b}(x) = \frac{\Gamma(a)\Gamma(b)}{\Gamma(a+b)} x^{a-1} (1-x)^{b-1} \mathbb{I}_{[0,1]}(x),$$

оù

$$\Gamma(a) = \int_0^\infty x^{a-1} e^{-x} \mathrm{d}x$$

est la fonction Gamma. La forme de cette densité pour a = b = 2 est présentée au graphique droit de la figure 2.2. À noter que l'on retrouve la densité uniforme sur [0,1] dans le cas particulier où a = b = 1. Pour une variable aléatoire  $X \sim f_{a,b}$ , on a

$$E(X) = \frac{a}{a+b}, \quad et \quad var(X) = \frac{ab}{(a+b)^2(a+b+1)}$$

Aussi,

$$\mathcal{E}(X^k) = \frac{\Gamma(a+b)\Gamma(a+k)}{\Gamma(a)\Gamma(a+b+k)}.$$

En particulier,

$$E(X^3) = \frac{a(a+1)(a+2)}{(a+b)(a+b+1)(a+b+2)}$$

et

$$E(X^4) = \frac{a(a+1)(a+2)(a+3)}{(a+b)(a+b+1)(a+b+2)(a+b+3)}.$$

Finalement, à l'aide des formules (2.4) et (2.5), on trouve

$$\beta_1 = \frac{2(b-a)\sqrt{a+b+1}}{(a+b+2)\sqrt{ab}}$$

et

$$\beta_2 = 6\left\{\frac{a^3 - a^2(2b - 1) + b^2(b + 1) - 2ab(b + 2)}{ab(a + b + 2)(a + b + 3)}\right\}$$

Dans le cas particulier où a = b, on déduit

$$\beta_1 = 0 \quad et \quad \beta_2 = \frac{-6}{2a+3} \,.$$

Pour la loi uniforme sur (0,1), c'est-à-dire quand a = b = 1, les formules précédentes donnent  $\beta_1 = 0$  et  $\beta_2 = -6/5$ , en accord avec les calculs de l'exemple 2.1.

**Exemple 2.3.** Soit une variable X de loi exponentielle de paramètre  $\lambda$ , c'està-dire dont la densité est

$$f_{\lambda}(x) = \frac{1}{\lambda} \exp\left(\frac{-x}{\lambda}\right) \mathbb{I}_{\mathbb{R}^+}(x).$$

Pour cette loi, on a  $E(X) = \lambda$ ,  $E(X^2) = 2\lambda^2$ ,  $E(X^3) = 6\lambda^3$  et  $E(X^4) = 24\lambda^4$ . Ainsi,

$$E\{(X - \lambda)^3\} = E(X^3) - 3\lambda E(X^2) + 3\lambda^2 E(X) - \lambda^3 = 2\lambda^3$$

~	4
С	ι

$$\mathbb{E}\left\{ (X-\lambda)^4 \right\} = \mathbb{E}(X^4) - 4\lambda \mathbb{E}(X^3) + 6\lambda^2 \mathbb{E}(X^2) - 4\lambda^3 \mathbb{E}(X) + \lambda^4 = 9\lambda^4.$$
  
Comme var(X) =  $\lambda^2$ , on a  $\beta_1 = 2$  et  $\beta_2 = 9$ .

Exemple 2.4. La densité de la loi double exponentielle standard est

$$f(x) = \frac{1}{2} e^{-|x|}.$$

La forme de cette densité est présentée au graphique gauche de la figure 2.2. On calcule facilement  $\mu = 0$  et  $\sigma^2 = 2$ . Ainsi,

$$\beta_1 = \frac{\mathcal{E}(X^3)}{(\sqrt{2})^3} = 0 \quad et \quad \beta_2 = \frac{\mathcal{E}(X^4)}{(\sigma^2)^2} = \frac{24}{4} = 6.$$

### 2.2 Test basé sur le coefficient d'asymétrie

La version empirique du coefficient d'asymétrie  $\beta_1$  est donnée par

$$\hat{\beta}_1 = \frac{1}{n} \sum_{i=1}^n \left( \frac{X_i - \hat{\mu}}{\hat{\sigma}} \right)^3.$$

Lorsque les observations  $X_1, \ldots, X_n$  proviennent d'une population de loi normale, le théorème de la limite centrale et la méthode *Delta* (voir van der Vaart & Wellner (1996)) permettent de montrer que  $\sqrt{n} \hat{\beta}_1$  converge en loi vers une loi normale de moyenne 0 et de variance 6. Un test de normalité consiste donc à rejeter l'hypothèse nulle lorsque  $|S_n| > \Phi^{-1}(1 - \alpha/2)$ , où

$$S_n = \frac{\sqrt{n\beta_1}}{\sqrt{6}} \tag{2.6}$$

et  $\Phi$  est la fonction de répartition de la loi normale standard.

### 2.3 Test basé sur le coefficient d'aplatissement

La version empirique du coefficient d'aplatissement  $\beta_2$  est donnée par

$$\hat{\beta}_2 = \frac{1}{n} \sum_{i=1}^n \left( \frac{X_i - \hat{\mu}}{\hat{\sigma}} \right)^4.$$

Lorsque les observations  $X_1, \ldots, X_n$  proviennent d'une population de loi normale, on peut montrer que  $\sqrt{n}(\hat{\beta}_2 - 3)$  converge en loi vers une loi normale de moyenne 0 et de variance 24. Un test de normalité consiste donc à rejeter l'hypothèse nulle lorsque  $|K_n| > \Phi^{-1}(1 - \alpha/2)$ , où

$$K_n = \frac{\sqrt{n}(\hat{\beta}_2 - 3)}{\sqrt{24}} \,. \tag{2.7}$$

### 2.4 Test de Jarque-Bera

La statistique du test de Jarque-Bera est

$$JB_n = S_n^2 + K_n^2, \qquad (2.8)$$

où  $S_n$  et  $K_n$  sont définies aux équations (2.6) et (2.7). Un test de normalité basé sur JB<sub>n</sub> a été introduit par D'Agostino & Pearson (1973) et popularisé par Jarque & Bera (1980, 1987). Vue sa forme, la statistique de Jarque-Bera est sensible à des écarts des coefficients d'asymétrie et d'aplatissement par rapport aux valeurs associées à la loi normale, à savoir  $\beta_1 = 0$  et  $\beta_2 = 3$ . Sous  $\mathcal{H}_0$ , les statistiques  $S_n$  et  $K_n$  sont indépendantes et asymptotiquement distribuées selon des normales centrées réduites. Par conséquent, JB<sub>n</sub> converge en loi vers une khi-carré à deux degrés de liberté. En pratique, toutefois, il vaut mieux éviter d'utiliser la valeur critique asymptotique, vue la faible vitesse de convergence de cette statistique. On emploie généralement les valeurs critiques estimées par des simulations de type Monte-Carlo.

### 2.5 Version robuste du test de Jarque-Bera

Une hypothèse implicite dans plusieurs procédures statistiques est l'absence de valeurs aberrantes. En particulier, les conclusions du test de Jarque-Bera peuvent être influencées par la présence de telles valeurs. Ceci a motivé Gel & Gastwirth (2008) à élaborer une version robuste de  $JB_n$ , à savoir

$$\widetilde{\mathrm{JB}}_n = \frac{n}{C_1} \left(\frac{\hat{\beta}_1}{J_n^3}\right)^2 + \frac{n}{C_2} \left(\frac{\hat{\beta}_2}{J_n^4} - 3\right)^2,$$

où

$$J_n = \frac{\sqrt{\pi/2}}{n} \sum_{i=1}^n |X_i - M_n|.$$

Ici,  $C_1, C_2$  sont des constantes et  $M_n$  est la médiane empirique. Sous  $\mathcal{H}_0$ , la statistique  $\widetilde{JB}_n$  a le même comportement asymptotique que  $JB_n$ .

## 2.6 Test de Gel et al. (2007)

L'écart-type  $\sigma$  est habituellement estimé par  $\hat{\sigma}=\sqrt{\hat{\sigma}^2},$  où

$$\hat{\sigma}^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \hat{\mu})^2.$$

Néanmoins, il est possible d'estimer  $\sigma$  autrement. En effet, dans le modèle normal, un estimateur sans biais est donné par

$$\tilde{\sigma}^2 = \sqrt{\frac{\pi}{2}} \frac{1}{n} \sum_{i=1}^n |X_i - \hat{\mu}|.$$

Ainsi, sous l'hypothèse nulle de normalité, le rapport  $\hat{\sigma}/\tilde{\sigma}$  devrait être près de 1. Ceci a motivé Gel et al. (2007) à proposer la statistique de test

$$\mathbf{R}_n = \sqrt{n} \left(\frac{\hat{\sigma}}{\tilde{\sigma}} - 1\right). \tag{2.9}$$

Ces auteurs démontrent que  $R_n$  converge en loi vers une normale de moyenne nulle et de variance  $\sigma_R^2 = (\pi - 3)/2$  sous l'hypothèse de normalité. Ainsi, un test de normalité de niveau de confiance asymptotique  $1 - \alpha$  consiste à rejeter l'hypothèse nulle lorsque

$$\frac{|\mathbf{R}_n|}{\sigma_R} > \Phi^{-1} \left( 1 - \frac{\alpha}{2} \right).$$

# CHAPITRE 3

# TESTS BASÉS SUR LA FONCTION DE RÉPARTITION

# 3.1 Processus empiriques pour l'adéquation

La fonction de répartition d'une variable aléatoire X à valeurs dans  $\mathbb R$  est définie par

$$F(x) = \mathcal{P}(X \le x).$$

Lorsque la loi de X est continue à valeurs dans  $\mathcal{D}$ , on a

$$F(x) = \int_{(-\infty,x)\cap\mathcal{D}} f(s) \,\mathrm{d}s,$$

où f est la densité de X. À partir de n copies indépendantes  $X_1, \ldots, X_n$  de X, on peut estimer F par la fonction de répartition empirique, à savoir

$$F_n(x) = \frac{1}{n} \sum_{i=1}^n \mathbb{I} \left( X_i \le x \right).$$

Ainsi, pour tout  $x \in \mathcal{D}$ ,  $F_n(x)$  est un estimateur sans biais de F(x) car

$$\mathbb{E}\left\{F_n(x)\right\} = \frac{1}{n}\sum_{i=1}^n \mathbb{E}\left\{\mathbb{I}\left(X_i \le x\right)\right\} = \frac{1}{n}\sum_{i=1}^n \mathbb{P}\left(X_i \le x\right) = \frac{nF(x)}{n} = F(x).$$

#### 3. Tests basés sur la fonction de répartition

De plus, on note que  $nF_n(x)$  est une binomiale de paramètres n et F(x). De là, on déduit que la variance de  $F_n(x)$  est  $F(x)\{1 - F(x)\}/n$ . De plus, si on applique le théorème de la limite centrale, on a que pour tout  $x \in \mathcal{D}$  fixé,

$$\mathbb{B}_n^{\star}(x) = \sqrt{n} \left\{ F_n(x) - F(x) \right\}$$

converge en loi vers la loi normale de moyenne 0 et de variance  $F(x)\{1 - F(x)\}$ . Pour tester l'adéquation à une fonction de répartition donnée F, une idée consiste à comparer  $F_n$  et F pour toutes les valeurs  $x \in \mathcal{D}$ . Cela amène à considérer  $\mathbb{B}_n^*(x)$  en tant que processus, c'est-à-dire comme une fonction aléatoire prenant ses valeurs dans un espace de fonctions. Un résultat classique assure que  $\mathbb{B}_n^*$  converge en loi vers un processus limite  $\mathbb{B}^*$ , où pour  $s \in \mathcal{D}$ fixé, la loi de  $\mathbb{B}^*(s)$  est normale de moyenne 0 et de variance  $F(s)\{1-F(s)\}$ , et  $\mathbb{E}\{\mathbb{B}^*(s)\mathbb{B}^*(t)\} = \min\{F(s), F(t)\} - F(s)F(t).$ 

Plus généralement, supposons que  $F(x) = F_{\theta}(x)$  dépend d'un paramètre inconnu  $\theta \in \Theta \subseteq \mathbb{R}^k$ . On souhaite tester l'adéquation à la famille paramétrique  $\mathcal{F}_{\theta} = \{F_{\theta}; \theta \in \Theta\}$  sur la base de  $F_n$ . Dans ce cas, Pourvu que l'on dispose d'un estimateur  $\hat{\theta}_n$  convergent pour  $\theta$ , une idée consiste à considérer le processus empirique à paramètres estimés

$$\mathbb{B}_n(x) = \sqrt{n} \left\{ F_n(x) - F_{\hat{\theta}_n}(x) \right\}.$$

Ce processus a été amplement étudié dans l'élaboration de tests d'adéquation. On pense notamment aux travaux de Stephens (1974, 1976).

Une approche alternative a été suggérée par Durbin (1973). Pour la décrire, soient les pseudo-observations  $\hat{T}_{i,n} = F_{\hat{\theta}_n}(X_i)$ . Sous l'hypothèse que la loi sous-jacente aux observations appartient à la famille  $\mathcal{F}_{\theta}$ , la loi de  $\hat{T}_{i,n}$ ,  $i \in$ 

#### 3. Tests basés sur la fonction de répartition

 $\{1, \ldots, n\}$  est approximativement uniforme sur (0, 1). Ceci vient du résultat théorique bien connu qui stipule que la loi de F(X) est uniforme sur (0, 1)lorsque  $X \sim F$  et que F est continue. Ceci a amené Durbin (1973) à considérer le processus empirique

$$\mathbb{F}_n(x) = \sqrt{n} \left\{ \frac{1}{n} \sum_{i=1}^n \mathbb{I}\left(\hat{T}_{i,n} \le t\right) - t \right\}.$$
(3.1)

Bien que les comportements de  $\mathbb{B}_n$  et  $\mathbb{F}_n$  soient différents pour des tailles échantillonales finies, leurs distributions asymptotiques sont identiques. Ainsi, quand  $n \to \infty$ ,  $\mathbb{B}_n$  et  $\mathbb{F}_n$  convergent vers un certain processus limite  $\mathbb{F}$ . Ce résultat est rappelé dans l'article présenté au Chapitre 6, où une technique différente pour le démontrer est offerte.

Dans ce mémoire, l'approche de Durbin (1973) sera privilégiée pour tester la normalité. Pour ce faire, on définit la fonction de répartition d'une variable aléatoire de loi  $\mathcal{N}(0,1)$  par  $\Phi$ . L'hypothèse de normalité est donc équivalente à l'appartenance de la fonction de répartition à la famille

$$\mathcal{F}_{\mu,\sigma} = \left\{ \Phi\left(\frac{x-\mu}{\sigma}\right); \mu \in \mathbb{R}, \sigma \in \mathbb{R}^+ \right\}.$$

Les pseudo-observations utilisées seront donc

$$\hat{T}_{i,n} = \Phi\left(\frac{X_i - \hat{\mu}}{\hat{\sigma}}\right), \quad 1 \le i \le n.$$

Dans la suite, trois tests d'adéquation sont définis comme fonctionnels du processus (3.1). Ce sont les distances de Cramér-von Mises, Anderson-Darling et Kolmogorov-Smirnov.

### 3.2 Le test de Cramér–von Mises

Une distance possible entre des fonctions de répartition consiste à prendre la moyenne des différences au carré. Cette idée a été explorée par Cramér (1928), von Mises (1931) et Smirnov & Polejaeff (1934). On réfère maintenant à cette fonctionnelle comme la distance de Cramér-von Mises. Dans notre cas, cela amène la statistique de test

$$\operatorname{CVM}_{n} = \int_{0}^{1} \left\{ \mathbb{F}_{n}(t) \right\}^{2} \mathrm{d}t.$$
(3.2)

En utilisant le fait que

$$\{\mathbb{F}_{n}(t)\}^{2} = \frac{1}{n} \sum_{i=1}^{n} \sum_{j=1}^{n} \mathbb{I}\left(t \ge \hat{T}_{i,n} \lor \hat{T}_{j,n}\right) - 2t \sum_{i=1}^{n} \mathbb{I}\left(t \ge \hat{T}_{i,n}\right) + nt^{2}, \quad (3.3)$$

on arrive à montrer, en intégrant entre 0 et 1, que

$$CVM_n = \frac{n}{3} + \sum_{i=1}^n \hat{T}_{i,n}^2 - \frac{1}{n} \sum_{i=1}^n \sum_{j=1}^n \left( \hat{T}_{i,n} \vee \hat{T}_{j,n} \right).$$
(3.4)

Puisque  $\mathbb{F}_n$  converge en loi vers la limite  $\mathbb{F}$ , on déduit que  $\text{CVM}_n$  converge en loi vers

$$\mathrm{CVM} = \int_0^1 \left\{ \mathbb{F}(t) \right\}^2 \, \mathrm{d}t.$$

On peut représenter cette loi limite en terme d'une somme pondérée de variables khi-carrés indépendantes. Toutefois, les valeurs critiques pour des tailles finies seront obtenues par des simulations Monte–Carlo.

## 3.3 Le test de Anderson–Darling

La statistique de Anderson-Darling est une version pondérée de la fonctionnelle de Cramér-von Mises. En fait, il s'agit de considérer une version pondérée du processus  $\mathbb{F}_n$  avec la fonction de poids  $t^{-1/2}(1-t)^{-1/2}$ . Ceci permet d'accorder plus d'importance aux valeurs de  $\mathbb{F}_n(t)$  près de 0 et 1. Cela peut s'avérer utile pour détecter des écarts à la normalité par des lois ayant des queues lourdes. Ainsi, la statistique du test de Anderson-Darling est définie par

$$AD_n = \int_0^1 \frac{\{\mathbb{F}_n(t)\}^2}{t(1-t)} \, \mathrm{d}t.$$
(3.5)

Ainsi,  $AD_n$  converge en loi vers

AD = 
$$\int_0^1 \frac{\{\mathbb{F}(t)\}^2}{t(1-t)} dt.$$

En utilisant (3.3), on montre que

$$AD_{n} = \frac{1}{n} \sum_{i=1}^{n} \sum_{j=1}^{n} \log\left(\frac{1}{\hat{T}_{i,n} \vee \hat{T}_{j,n}} - 1\right) - 2\sum_{i=1}^{n} \log\left(1 - \hat{T}_{i,n}\right) - n. \quad (3.6)$$

La moyenne et la variance de AD sont données par

$$\begin{split} & \mathcal{E}(\mathcal{AD}) = \int_{0}^{1} \frac{\mathcal{E}\left\{\mathbb{F}(t)\right\}^{2}}{t(1-t)} \, \mathrm{d}t = \int_{0}^{1} \frac{t(1-t)}{t(1-t)} \, \mathrm{d}t = 1, \\ & \text{var}\left(\mathcal{AD}\right) = \int_{0}^{1} \int_{0}^{1} \cos\left\{\frac{\mathbb{F}^{2}(s)}{s(1-s)}, \frac{\mathbb{F}^{2}(t)}{t(1-t)}\right\} \, \mathrm{d}s \mathrm{d}t = \frac{2}{3} \left(\pi^{2} - 9\right). \end{split}$$

### 3.4 Le test de Kolmogorov–Smirnov

Tel que mentionné par Stephens (1974, 1976), ce test s'inspire de la statistique proposée par Kolmogorov (1933) pour l'ajustement à une distribution. L'idée consiste à calculer la différence maximale, en valeur absolue, entre la distribution empirique et la distribution supposée sous l'hypothèse nulle. Pour tester la normalité, la statistique à utiliser est définie par

$$\mathrm{KS}_n = \sqrt{n} \sup_{t \in [0,1]} |F_n(t) - t| \,.$$

Puisque la fonction  $F_n(t)$  présente des *sauts* de hauteur 1/n lorsque  $t \in {\hat{T}_{1,n}, \ldots, \hat{T}_{n,n}} = {1/n, 2/n \ldots, 1}$ , on en déduit que

$$KS_{n} = \sqrt{n} \max_{1 \le i \le n} \left\{ \left| \hat{T}_{(i),n} - \frac{i}{n} \right|, \left| \hat{T}_{(i),n} - \frac{i-1}{n} \right| \right\},$$
(3.7)

où  $\hat{T}_{(1),n}, \ldots, \hat{T}_{(n),n}$  sont les statistiques d'ordre de l'échantillon  $\hat{T}_{1,n}, \ldots, \hat{T}_{n,n}$ . L'hypothèse de normalité est rejetée pour de grandes valeurs de KS<sub>n</sub>. Les valeurs critiques de cette statistique de test s'obtiennent aisément par une méthode Monte-Carlo. À partir du comportement asymptotique du processus  $\mathbb{F}_n$ , on déduit facilement celui de KS<sub>n</sub> :

$$\mathrm{KS}_n = \sup_{t \in [0,1]} |\mathbb{F}_n(t)| \rightsquigarrow \mathrm{KS} = \sup_{t \in [0,1]} |\mathbb{F}(t)|,$$

où ~> signifie convergence en loi.

## **CHAPITRE 4**

## AUTRES TESTS

# 4.1 Tests de régression

#### 4.1.1 Idée générale

La régression est un modèle mathématique utilisé pour expliquer le lien entre deux ou plusieurs variables aléatoires. Plus spécifiquement, on s'intéresse à l'effet qu'ont des variables *explicatives*  $X_1, \ldots, X_d$  sur une variable *dépendante* Y. La régression linéaire propose que ce lien soit de la forme

$$Y = \beta_0 + \sum_{j=1}^d \beta_j X_j + \epsilon,$$

où  $\epsilon \sim \mathcal{N}(0, \sigma^2)$ . À partir d'un échantillon  $(Y_i, X_{1i}, \ldots, X_{di}), i \in \{1, \ldots, n\}$ , on cherche les valeurs des paramètres  $(\beta_0, \beta_1, \ldots, \beta_d)$  qui font en sorte que la droite de régression soit le plus près possible des observations. Un tel critère de proximité est donné par la méthode des moindres carrés, qui consiste à choisir  $(\beta_0, \beta_1, \ldots, \beta_d)$  qui minimisent

$$L(\beta_0, \beta_1, \dots, \beta_d) = \sum_{i=1}^n \left( Y_i - \beta_0 - \sum_{j=1}^d \beta_j X_{ji} \right)^2.$$

La solution  $(\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_d)$  constitue les estimateurs de moindres carrés.

#### 4.1.2 Test de Shapiro–Wilk

Soit  $F_n$ , la fonction de répartition d'un échantillon  $X_1, \ldots, X_n$ . On peut définir les statistiques d'ordre par

$$X_{(i)} = F_n^{-1}\left(\frac{i}{n}\right).$$

Sous l'hypothèse de normalité,  $F_n^{-1}(u)$  est un bon estimateur de  $\Phi_{\mu,\sigma}^{-1}(u) = \sigma \Phi^{-1}(u) + \mu$ . Ainsi, la statistique d'ordre  $X_{(i)}$  devrait être fortement corrélée avec  $\Phi^{-1}(i/n)$ . Ainsi, la régression linéaire

$$\Phi^{-1}\left(\frac{i}{n}\right) = \beta_0 + \beta_1 X_{(i)} + \epsilon$$

devrait être significative. La statistique du test de Shapiro-Wilk est

$$W_n = \frac{\left(\sum_{i=1}^n a_i X_{(i)}\right)^2}{(n-1)S_n^2}, \quad \text{où} \ (a_1, \dots, a_n) = \frac{m' \Sigma^{-1}}{(m' \Sigma^{-1} \Sigma^{-1} m)^{1/2}},$$

avec  $m = (m_1, \ldots, m_n)$ ,  $m_i = E(X_{(i)})$  et  $\Sigma$  est la matrice de variancecovariance des statistiques d'ordre  $X_{(1)}, \ldots, X_{(n)}$ . La statistique  $W_n$  s'interprète comme un coefficient de corrélation quadratique entre les distributions observée et normale. Sous  $\mathcal{H}_0$ , la statistique  $W_n$  prend des valeurs près de 1. On rejette l'hypothèse lorsque  $W_n$  est inférieure à la valeur critique qui peut être extraite d'une table de Shapiro-Wilk.
### 4.1.3 Test de D'Agostino

La statistique de D'Agostino est une alternative à la statistique de test de Shapiro–Wilk. Son avantage principal est qu'elle est plus simple et plus rapide à calculer. Spécifiquement, on a

$$D_n = \frac{\left(\sum_{i=1}^n a_i X_{(i)}\right)^2}{(n-1)\hat{\sigma}^2} \,,$$

оù

$$a_i = i - \frac{n+1}{2}$$

On peut montrer que

$$\lim_{n \to \infty} \mathcal{E}(D_n) = \frac{1}{2\sqrt{\pi}} \quad \text{et} \quad \lim_{n \to \infty} \operatorname{var}(D_n) \approx \frac{0.03}{\sqrt{n}}$$

Une version normalisée de  $D_n$  est alors

$$\tilde{D}_n = \frac{\sqrt{n}}{0.03} \left( D_n - \frac{1}{2\sqrt{\pi}} \right).$$

On rejette l'hypothèse de normalité quand

$$\left|\tilde{D}_n\right| > \Phi^{-1}\left(1 - \frac{\alpha}{2}\right).$$

# 4.2 Test basé sur l'entropie d'une loi de probabilité

#### 4.2.1 Notion d'entropie

L'entropie d'une fonction de densité f est définie par

$$\mathbb{E}(f) = -\int_{-\infty}^{\infty} f(x) \log f(x) \, \mathrm{d}x.$$

Pour la densité normale de moyenne  $\mu$  et de variance  $\sigma^2$ , on calcule

$$\mathbb{E}(\phi_{\mu,\sigma}) = -\int_{-\infty}^{\infty} \phi_{\mu,\sigma}(x) \log \phi_{\mu,\sigma}(x) \, \mathrm{d}x.$$

En appliquant le changement de variable  $z = (x - \mu)/\sigma$ , on a

$$\begin{split} \mathbb{E} \left( \phi_{\mu,\sigma}^{-} \right) &= -\int_{-\infty}^{\infty} \phi(z) \log \left\{ \frac{1}{\sigma} \phi(z) \right\} \, \mathrm{d}z \\ &= \log \sigma \int_{-\infty}^{\infty} \phi(z) \mathrm{d}z - \int_{-\infty}^{\infty} \phi(z) \log \phi(z) \mathrm{d}z \\ &= \log \sigma + \log \sqrt{2\pi} \int_{-\infty}^{\infty} \phi(z) \mathrm{d}z + \frac{1}{2} \int_{-\infty}^{\infty} z^{2} \phi(z) \mathrm{d}z \\ &= \log \sigma + \log \sqrt{2\pi} + \frac{1}{2} \\ &= \frac{1}{2} \log \left( 2\pi e \sigma^{2} \right). \end{split}$$

On remarque que l'entropie de la densité normale ne dépend pas de la moyenne  $\mu$ . Toutefois, l'entropie augmente comme fonction de l'écart-type. La figure 4.1 présente la courbe de  $\mathbb{E}(\phi_{\mu,\sigma})$  en fonction de  $\sigma$ .



Figure 4.1: Entropie de la densité normale en fonction de l'écart-type  $\sigma$ 

#### 4.2.2 Test de Vasicek

Une idée de test de normalité consiste à comparer une version empirique de l'entropie à la valeur théorique sous  $\mathcal{H}_0$ . L'hypothèse nulle est alors rejetée pour de grandes différences observées. On estime  $\mathbb{E}(f)$  par

$$\mathbb{E}_{mn} = \frac{1}{n} \sum_{i=1}^{n} \log \left\{ \frac{n}{2m} \left( X_{(i+m)} - X_{(i-m)} \right) \right\},\,$$

où m < n/2 est un entier positif et  $X_{(i)}$  est la *i*-ème statistique d'ordre. Par convention, on pose  $X_{(i)} = X_{(1)}$  si i < 1 et  $X_{(i)} = X_{(n)}$  si i > n.

Pour élaborer une statistique de test pour la normalité, on note que

$$\exp\left\{\mathbb{E}\left(\phi_{\mu,\sigma}\right)\right\} = \sqrt{2\pi e}\sigma \quad \text{et} \quad \exp\left(\mathbb{E}_{mn}\right) = \frac{n}{2m} \left\{\prod_{i=1}^{n} \left(X_{(i+m)} - X_{(i-m)}\right)\right\}^{1/n}.$$

En prenant le ratio, on a

$$\frac{\exp\left(\mathbb{E}_{mn}\right)}{\exp\left\{\mathbb{E}\left(\phi_{\mu,\sigma}\right)\right\}} = \frac{n}{2m\sqrt{2\pi e\sigma}} \left\{\prod_{i=1}^{n} \left(X_{(i+m)} - X_{(i-m)}\right)\right\}^{1/n}$$

#### 4. Autres tests

En négligeant la constante  $\sqrt{2\pi e}$  et en estimant  $\sigma$  par son estimateur naturel  $\hat{\sigma}$ , on retrouve la statistique de test

$$V_{mn} = \frac{n}{2mS} \left\{ \prod_{i=1}^{n} \left( X_{(i+m)} - X_{(i-m)} \right) \right\}^{1/n}.$$

Les valeurs critiques du test de normalité basé sur  $V_{mn}$  pour différentes valeurs de n et m se retrouvent dans l'article de Vasicek (1976). Une étude de puissance conduite par cet auteur montre que la puissance de  $V_{mn}$  est souvent comparable aux tests de Shapiro-Wilk et de Anderson-Darling.

## CHAPITRE 5

## ÉVALUATION DE LA PUISSANCE POUR DES TAILLES FINIES

### 5.1 Alternatives locales à la loi normale

Dans ce chapitre, des contre-hypothèses à la distribution normale seront décrites. Les densités associées à ces alternatives sont de la forme  $\ell_{\delta}$ , où  $\lim_{\delta \to 0} \ell_{\delta}(z) = \phi(z)$ . Ainsi, il sera possible d'étudier l'efficacité de tests de normalité sous des hypothèses très semblables à la normale.

#### 5.1.1 Mélanges de lois normales

Une façon de créer des alternatives à une loi consiste à considérer des mélanges de lois. Dans le cas de la loi normale, une possibilité consiste à considérer des densités de la forme

$$\ell_{\delta}(z) = (1-\delta)\phi(z) + \frac{\delta}{\gamma}\phi\left(\frac{z-\nu}{\gamma}\right).$$
(5.1)

Un tel mélange de lois fut utilisé par Thadewald & Büning (2007) pour étudier la puissance de quelques tests de normalité sous de petits échantillons. La figure 5.1 présente des mélanges de lois normales pour  $\gamma = 1$  pour différentes valeurs de  $\delta$ .



Figure 5.1: Mélanges de lois  $\mathcal{N}(0, 1)$  et  $\mathcal{N}(\nu, 1)$  pour différentes valeurs de  $\delta$ . À gauche,  $\nu = 1$ ; à droite,  $\nu = 2$ 

On voit sur la figure 5.1 que plus la moyenne  $\nu$  augmente, plus la distribution s'éloigne de la normalité. Ainsi, la capacité des tests de normalité à rejeter  $\mathcal{H}_0$  devrait croître en fonction de  $\nu$ . Pour ce qui est du paramètre  $\delta$ , on note que les valeurs  $\delta = 0$  et  $\delta = 1$  amène des modèles sous  $\mathcal{H}_0$ . Ainsi, la puissance des tests devrait être faible près de ces valeurs. La différence la plus marquée par rapport à la normalité se produit lorsque  $\delta = 1/2$ .

La figure 5.2 présente des mélanges de lois normales lorsque  $\nu = 0$  et  $\gamma = 2$ , et ce pour différentes valeurs de  $\delta$ . Cette fois, le paramètre  $\delta$  n'agit pas sur l'asymétrie de la distribution, mais plutôt sur son coefficient d'aplatissement.



Figure 5.2: Mélanges de lois  $\mathcal{N}(0,1)$  et  $\mathcal{N}(0,4)$  pour différentes valeurs de  $\delta$ 

#### 5.1.2 Alternative à queues lourdes

Soient des mélanges de la forme

$$\ell_{\delta}(z) = \begin{cases} \phi(z), & z < 0; \\ (1 - \delta)\phi(z) + \delta g(z), & z \ge 0. \end{cases}$$
(5.2)

où g est une certaine densité symétrique par rapport à 0. La figure 5.3 présente les densités obtenues lorsque g est la densité de Student avec  $\nu = 5$ et  $\nu = 10$  degrés de liberté. On remarque d'emblée une grande similarité entre ces distributions et la distribution normale, même en faisant varier les valeurs de  $\delta$ . Les différences se retrouvent principalement au niveau des ailes des distributions, mais celles-ci s'amoindrissent à mesure que  $\nu$  augmente. Cette famille de distributions alternatives permettra d'évaluer la puissance des tests de normalité sous des alternatives ayant des ailes plus lourdes que celles de la loi normale.

#### 5. PUISSANCE À TAILLES FINIES



Figure 5.3: Alternative à queues lourdes lorsque g est la densité de Student. À gauche,  $\nu = 5$ ; à droite,  $\nu = 10$ 

#### 5.1.3 Une alternative asymétrique

Azzalini (1985) a introduit la famille de densités

$$\ell_{\delta}(z) = 2\phi(z)\Phi(\delta z). \tag{5.3}$$

Comme cas particulier, on retrouve la densité normale pour  $\delta = 0$  car

$$\lim_{\delta \to 0} \ell_{\delta}(z) = 2\phi(z)\Phi(0) = \phi(z),$$

puisque  $\Phi(0) = P(Z \le 0) = 1/2$ , où  $Z \sim \mathcal{N}(0, 1)$ . La figure 5.4 présente cette densité pour quelques valeurs de  $\delta$ . À mesure que  $\delta$  augmente, on voit que la densité devient de plus en plus asymétrique. Ces lois permettront de juger de l'efficacité des tests à rejeter des hypothèses présentant de l'asymétrie.



Figure 5.4: Densités asymétriques avec diverses valeurs de  $\delta$ 

## 5.2 Résultats des simulations

Étudier la puissance des tests est une étape cruciale pour qu'un statisticien puisse choisir une méthode appropriée parmi la panoplie de tests disponibles. Plusieurs études de ce genre ont été effectuées, notamment par Shapiro et al. (1968), Stephens (1974) et Pearson et al. (1977). Dans toutes ces investigations, les distributions alternatives considérées sont passablement éloignées de la distribution sous  $\mathcal{H}_0$ , à savoir la loi normale. Il en résulte, tel qu'attendu, des puissances élevées pour la plupart des procédures. On serait beaucoup plus intéressé à connaître le comportement des tests dans des cas où la loi est proche de la normalité.

Dans cette section, une étude de puissance pour quelques-uns des tests décrits aux chapitres 2, 3 et 4 sera élaborée. Les alternatives considérées seront de type *local.* Précisément, on considérera des contre-hypothèses de la forme (5.1), (5.2) et (5.3). Les procédures considérées seront basées sur les statistiques  $S_n$ ,  $K_n$ ,  $JB_n$ ,  $R_n$ ,  $CVM_n$ ,  $AD_n$  et  $KS_n$ . Pour effectuer les tests, les valeurs critiques obtenues d'une simulation de type Monte-Carlo seront utilisées. Les résultats se retrouvent au tableau 6.1 du chapitre 6.

#### 5.2.1 Puissance sous des mélanges de lois normales

Soient les densités de la forme

$$\ell_{\delta}(z) = (1 - \delta)\phi(z) + \delta\phi(z - \nu).$$

Il s'agit d'un cas particulier du modèle (5.1) lorsque  $\gamma = 1$ . Si  $X \sim \ell_{\delta}$ , alors

$$\mathbf{E}(X^j) = (1 - \delta)\mathbf{E}(Z^j) + \delta\mathbf{E}\{(Z + \nu)^j\},\$$

où  $Z \sim \mathcal{N}(0,1)$ . Ceci permet de calculer  $E(X) = \delta \nu$ ,  $E(X^2) = 1 + \delta \nu^2$ ,  $E(X^3) = \delta(3\nu + \nu^3)$  et  $E(X^4) = 3 + \delta \nu^2 (\nu^2 + 6)$ . Ainsi,  $\operatorname{var}(X) = 1 + \delta(1 - \delta)\nu^2$ et les coefficients d'asymétrie et d'aplatissement sont respectivement

$$\beta_{1} = \frac{\delta(1-\delta)(1-2\delta)\nu^{3}}{\{1+\delta(1-\delta)\nu^{2}\}^{3/2}},$$
  
$$\beta_{2} = \frac{3+\delta(1-\delta)\nu^{2}\{6+(3\delta^{2}-3\delta+1)\nu^{2}\}}{\{1+\delta(1-\delta)\nu^{2}\}^{2}}.$$

La figure 5.5 montre le comportement de  $\beta_1$  et  $\beta_2$  en fonction du paramètre  $\delta$  lorsque  $\nu = 1$ . On retrouve les valeurs typiques du modèle normal, à savoir  $\beta_1 = 0$  et  $\beta_2 = 3$ , quand  $\delta = 0$  et  $\delta = 1$ , ce qui s'explique par le fait qu'on se retrouve sous  $\mathcal{H}_0$ . Cependant, ces valeurs sont également visitées sous  $\mathcal{H}_1$ . En effet,  $\beta_1 = 0$  pour  $\delta = 1/2$ , alors que  $\beta_2 = 3$  pour  $\delta = 1/2 \pm \sqrt{3}/6$ .



Figure 5.5: Coefficients d'asymétrie (en haut) et d'aplatissement (en bas) en fonction de  $\delta$  dans le modèle (5.1) quand  $\nu = 1$  et  $\gamma = 1$ 

Le tableau 5.1 présente les puissances estimées sous le modèle (5.1) avec  $\nu = \gamma = 1$ . En examinant les résultats pour  $\delta = 0$  et  $\delta = 1$ , on constate que toutes les statistiques conservent leur seuil sous  $\mathcal{H}_0$ , et ce pour toutes les tailles d'échantillons. Sauf pour  $S_n$  et  $K_n$ , les puissances des tests atteignent leur apogée lorsque  $\delta = 0.5$ , c'est-à-dire lorsque l'alternative (5.1) est la plus éloignée de l'hypothèse nulle. Les faibles puissances de  $S_n$  et  $K_n$  s'expliquent par les faibles variations des coefficients d'asymétrie et d'aplatissement, tel qu'on peut le constater à la figure 5.5. Globalement,  $R_n$  est la meilleure.

n	δ	S <sub>n</sub>	$\mathbf{K}_n$	$JB_n$	$\mathbb{R}_n$	$\mathrm{CVM}_n$	$AD_n$	$\mathrm{KS}_n$
	0	0.0487	0.0487	0.0502	0.0530	0.0491	0.0486	0.0474
	0.25	0.0485	0.0468	0.3743	0.3654	0.1995	0.2328	0.1498
50	0.5	0.0433	0.0425	0.2657	0.3393	0.1810	0.2025	0.1430
	0.75	0.0481	0.0464	0.1249	0.1789	0.0955	0.1005	0.0861
	1	0.0504	0.0486	0.0463	0.0480	0.0504	0.0526	0.0492
	0	0.0488	0.0508	0.0512	0.0559	0.0569	0.0582	0.0568
	0.25	0.0558	0.0450	0.5650	0.5774	0.3210	0.3799	0.2360
100	0.5	0.0395	0.0433	0.4098	0.5514	0.3075	0.3410	0.2247
	0.75	0.0536	0.0473	0.1712	0.2857	0.1433	0.1517	0.1156
	1	0.0507	0.0481	0.0503	0.0562	0.0563	0.0577	0.0545
	0	0.0522	0.0575	0.0489	0.0551	0.0476	0.0474	0.0508
	0.25	0.0968	0.0558	0.9836	0.9821	0.8886	0.9383	0.7399
500	0.5	0.0423	0.0581	0.9354	0.9885	0.9098	0.9377	0.7824
	0.75	0.0987	0.0540	0.4504	0.7676	0.4906	0.5105	0.3593
	1	0.0504	0.0608	0.0473	0.0540	0.0530	0.0529	0.0562

Tableau 5.1: Estimation, basée sur 10 000 répétitions, de la puissance de  $S_n$ ,  $K_n$ ,  $JB_n$ ,  $R_n$ ,  $CVM_n$ ,  $AD_n$  et  $KS_n$  sous l'alternative (5.1) avec  $\nu = 1$  et  $\gamma = 1$ 

#### 5.2.2 Puissance sous l'alternative à queues lourdes

Les tableaux 5.2, 5.3, 5.4 et 5.5 présentent les puissances estimées des statistiques sous l'alternative 5.2. Spécifiquement, le modèle à queues lourdes fournit par la densité de Student à  $\nu = 5, 10, 20$  et 30 degrés de liberté est utilisé pour construire les contre-hypothèses.

On remarque d'abord que les puissances, globalement, augmentent avec les tailles des échantillons, tel qu'attendu. De plus, les puissances observées décroissent en fonction du paramètre  $\nu$ . Cela s'explique par le fait que la densité de Student s'approche de celle de la loi normale standard, donc de  $\mathcal{H}_0$ , à mesure que  $\nu$  augmente. Aussi, contrairement au modèle 5.1, les puissances sont croissantes en fonction de  $\delta$ . En fait, plus  $\delta \in [0, 1]$  prend une valeur élevée, plus le poids accordé à la densité de Student est important, d'où la plus grande capacité à rejeter  $\mathcal{H}_0$ .

Contrairement aux résultats sous des mélanges de lois normales, toutes les statistiques montrent des puissances appréciables. Néanmoins, les procédures basées sur JB<sub>n</sub> et R<sub>n</sub> sont les meilleures, et ce pour tous les scénarios considérés. La statistique de Kolmogorov-Smirnov KS<sub>n</sub> est la moins puissante parmi les sept statistiques étudiées. On remarque également que malgré leur grande simplicité, les statistiques S<sub>n</sub> et K<sub>n</sub> font aussi bien, sinon mieux, que les fonctionnelles du processus empirique  $\mathbb{F}_n$ , c'est-à-dire CVM<sub>n</sub>, AD<sub>n</sub> et KS<sub>n</sub>.

n	δ	$\mathbf{S}_{n}$	$\mathbf{K}_n$	$JB_n$	$\mathbf{R}_n$	$\mathrm{CVM}_n$	$AD_n$	$\mathrm{KS}_n$
	0.25	0.1228	0.1250	0.1971	0.1683	0.1041	0.1192	0.0857
50	0.5	0.2040	0.1832	0.3070	0.2807	0.1612	0.1896	0.1342
	0.75	0.2648	0.2312	0.3804	0.3684	0.2220	0.2521	0.1748
	1	0.3229	0.2710	0.4208	0.4410	0.2761	0.3072	0.2147
	0.25	0.1705	0.1795	0.3096	0.2643	0.1438	0.1620	0.1197
100	0.5	0.2991	0.2895	0.4868	0.4454	0.2535	0.2982	0.1970
	0.75	0.4100	0.3665	0.5775	0.5652	0.3492	0.4063	0.2679
	1	0.5113	0.4351	0.6467	0.6799	0.4485	0.4955	0.3491
	0.25	0.4517	0.4850	0.7278	0.6273	0.3231	0.3825	0.2292
500	0.5	0.7707	0.7498	0.9322	0.9045	0.6733	0.7417	0.5243
	0.75	0.9204	0.8724	0.9823	0.9844	0.8891	0.9008	0.7694
	1	0.9750	0.9350	0.9955	0.9966	0.9662	0.9535	0.9053

Tableau 5.2: Estimation, basée sur 10 000 répétitions, de la puissance de  $S_n$ ,  $K_n$ ,  $JB_n$ ,  $R_n$ ,  $CVM_n$ ,  $AD_n$  et  $KS_n$  sous l'alternative (5.2) avec  $\nu = 5$ 

n	δ	$S_n$	$\mathbf{K}_n$	$JB_n$	$\mathbf{R}_n$	$\mathrm{CVM}_n$	$AD_n$	$\mathrm{KS}_n$
	0.25	0.0701	0.0701	0.0979	0.0876	0.0595	0.0663	0.0580
50	0.5	0.0960	0.0895	0.1435	0.1252	0.0795	0.0872	0.0717
	0.75	0.1169	0.1027	0.1747	0.1615	0.0901	0.1042	0.0769
	1	0.1488	0.1246	0.2011	0.1938	0.1075	0.1229	0.0890
	0.25	0.0864	0.0895	0.1342	0.1175	0.0705	0.0761	0.0646
100	0.5	0.1266	0.1247	0.2033	0.1798	0.0957	0.1070	0.0814
	0.75	0.1679	0.1590	0.2599	0.2417	0.1207	0.1404	0.0990
	1	0.2040	0.1796	0.3107	0.3072	0.1498	0.1706	0.1157
	0.25	0.1523	0.1758	0.2845	0.2228	0.0892	0.0980	0.0721
500	0.5	0.2966	0.3000	0.4943	0.4314	0.1734	0.2037	0.1254
	0.75	0.4615	0.4145	0.6454	0.6171	0.2903	0.3406	0.1992
	1	0.6009	0.5063	0.7478	0.7552	0.4234	0.4881	0.2892

Tableau 5.3: Estimation, basée sur 10 000 répétitions, de la puissance de  $S_n$ ,  $K_n$ ,  $JB_n$ ,  $R_n$ ,  $CVM_n$ ,  $AD_n$  et  $KS_n$  sous l'alternative (5.2) avec  $\nu = 10$ 

Tableau 5.4:	Estimation,	basée sur 1	0 000 répétitions	, de	la puissance d	$e S_n,$
$K_n, JB_n, R_n$	, $\text{CVM}_n$ , $\text{AD}$	$_n$ et $\mathrm{KS}_n$ so	us l'alternative (	5.2)	avec $\nu = 20$	

$\overline{n}$	δ	$S_n$	$\mathbf{K}_n$	$JB_n$	$\mathbf{R}_n$	$\mathrm{CVM}_n$	$AD_n$	$\mathrm{KS}_n$
	0.25	0.0520	0.0525	0.0636	0.0626	0.0531	0.0540	0.0504
50	0.5	0.0670	0.0661	0.0862	0.0796	0.0586	0.0599	0.0554
	0.75	0.0698	0.0656	0.0966	0.0926	0.0617	0.0653	0.0583
	1	0.0824	0.0736	0.1137	0.1060	0.0658	0.0693	0.0611
	0.25	0.0619	0.0597	0.0818	0.0767	0.0608	0.0631	0.0590
100	0.5	0.0716	0.0709	0.1095	0.0979	0.0666	0.0677	0.0613
	0.75	0.0833	0.0853	0.1287	0.1224	0.0739	0.0772	0.0711
	1	0.1001	0.0941	0.1513	0.1512	0.0806	0.0888	0.0732
	0.25	0.0706	0.0872	0.0825	0.0776	0.0522	0.0521	0.0534
500	0.5	0.1160	0.1178	0.1120	0.1203	0.0603	0.0632	0.0574
	0.75	0.1662	0.1625	0.1565	0.1527	0.0672	0.0720	0.0612
	1	0.2184	0.1989	0.1936	0.1980	0.0812	0.0880	0.0704

.

.

.

$\overline{n}$	δ	$S_n$	K <sub>n</sub>	$JB_n$	$R_n$	$\mathrm{CVM}_n$	$AD_n$	$\mathrm{KS}_n$
	0.25	0.0496	0.0483	0.0609	0.0567	0.0470	0.0485	0.0511
50	0.5	0.0575	0.0557	0.0712	0.0670	0.0557	0.0564	0.0543
	0.75	0.0639	0.0584	0.0837	0.0783	0.0532	0.0537	0.0531
	1	0.0667	0.0632	0.0885	0.0873	0.0600	0.0621	0.0584
	0.25	0.0572	0.0577	0.0683	0.0684	0.0551	0.0572	0.0539
100	0.5	0.0628	0.0620	0.0861	0.0813	0.0601	0.0652	0.0572
	0.75	0.0647	0.0711	0.0936	0.0951	0.0634	0.0677	0.0589
	1	0.0746	0.0739	0.1090	0.1115	0.0664	0.0694	0.0642
	0.25	0.0637	0.0696	0.0829	0.0825	0.0575	0.0559	0.0553
500	0.5	0.0803	0.0897	0.1179	0.1221	0.0662	0.0668	0.0614
	0.75	0.0982	0.1030	0.1557	0.1530	0.0681	0.0710	0.0619
	1	0.1326	0.1277	0.1923	0.1998	0.0811	0.0880	0.0706

Tableau 5.5: Estimation, basée sur 10 000 répétitions, de la puissance de  $S_n$ ,  $K_n$ ,  $JB_n$ ,  $R_n$ ,  $CVM_n$ ,  $AD_n$  et  $KS_n$  sous l'alternative (5.2) avec  $\nu = 30$ 

#### 5. PUISSANCE À TAILLES FINIES

#### 5.2.3 Puissance sous une alternative asymétrique

Soient les densités introduites à l'équation (5.3). Dans ce cas, on a

$$\mathcal{E}(X^k) = \int_{\mathbb{R}} x^k \ell_{\delta}(x) \mathrm{d}x,$$

où  $\ell_{\delta}(x) = 2\phi(x)\Phi(\delta x)$ . En effectuant le changement de variable u = -x et en notant que  $\ell_{\delta}(-u) = 2\phi(u)\{1 - \Phi(\delta u)\}$ , on trouve

$$E(X^{k}) = \int_{\mathbb{R}} 2(-1)^{k} u^{k} \phi(u) \{1 - \Phi(\delta u)\} du$$
  
=  $2(-1)^{k} \int_{\mathbb{R}} u^{k} \phi(u) du - (-1)^{k} \int_{\mathbb{R}} u^{k} \ell_{\delta}(u) du$   
=  $2(-1)^{k} E(Z^{k}) - (-1)^{k} E(X^{k}),$ 

où  $Z \sim \mathcal{N}(0,1)$ . Ainsi, si k est pair, on a  $E(X^k) = E(Z^k)$ . En particulier,  $E(X^2) = 1$  et  $E(X^4) = 3$ . En utilisant MAPLE, on trouve

$$\mu = \mathcal{E}(X) = \sqrt{\frac{2}{\pi}} \frac{\delta}{\sqrt{\delta^2 + 1}} \quad \text{et} \quad \mathcal{E}(X^3) = \sqrt{\frac{2}{\pi}} \frac{\delta (2\delta^2 + 3)}{(\delta^2 + 1)^{3/2}}.$$

Un peu d'algèbre permet de déduire que

$$\sigma^{2} = \frac{(\pi - 2)\delta^{2} + \pi}{\pi \left(\delta^{2} + 1\right)}.$$

Les expressions pour  $\beta_1$  et  $\beta_2$  en fonction de  $\delta$  on une forme relativement compliquée, bien qu'elles puissent facilement s'obtenir avec MAPLE. La figure 5.6 montre d'ailleurs l'influence du paramètre  $\delta$  sur l'asymétrie et l'aplatissement de la densité (5.3). Comme on peut le constater, l'asymétrie à droite est fortement influencée par l'augmentation de  $\delta$ . Pour le coefficient d'aplatissement, celui-ci s'écarte moins de la valeur sous  $\mathcal{H}_0$ , soit  $\beta_2 = 3$ .



Figure 5.6: Coefficients d'asymétrie (en haut) et d'aplatissement (en bas) en fonction de  $\delta$  dans le modèle (5.3)

Au tableau 5.6, les puissances des sept statistiques sont estimées sous le modèle (5.3). Globalement, le test basé sur  $S_n$  est le plus puissant. Il est suivi par les procédures basées sur les statistiques de Jarque-Bera et de Anderson-Darling, respectivement JB<sub>n</sub> et AD<sub>n</sub>. Cette excellente performance de S<sub>n</sub> s'explique par l'influence importante de  $\delta$  sur le coefficient d'asymétrie, tel qu'on peut le constater à la figure 5.6. La statistique de Gel et al. (2007), à savoir R<sub>n</sub>, est la moins performante. La statistique K<sub>n</sub>, basée sur le coefficient d'aplatissement, a également une faible puissance. Cela s'explique par la relative insensibilité de  $\beta_2$  en fonction de  $\delta$ , tel que vu à la figure 5.6.

Tableau 5.6: Estimation, basée sur 10 000 répétitions, de la puissance de  $S_n$ ,  $K_n$ ,  $JB_n$ ,  $R_n$ ,  $CVM_n$ ,  $AD_n$  et  $KS_n$  sous l'alternative (5.3)

n	δ	$S_n$	K <sub>n</sub>	$JB_n$	$\mathbf{R}_n$	$\mathrm{CVM}_n$	$AD_n$	$\mathrm{KS}_n$
50	1	0.0663	0.0570	0.0688	0.0596	0.0614	0.0634	0.0588
	2	0.2279	0.1021	0.1880	0.0961	0.1534	0.1687	0.1381
	3	0.4113	0.1450	0.3408	0.1249	0.3148	0.3516	0.2533
	1	0.0835	0.0619	0.0862	0.0674	0.0722	0.0757	0.0734
100	2	0.4091	0.1298	0.3537	0.1298	0.2878	0.3196	0.2407
	3	0.7197	0.2018	0.6404	0.1728	0.5887	0.6438	0.4797
500	1	0.2416	0.0870	0.1934	0.0826	0.1333	0.1469	0.1159
	2	0.9812	0.3128	0.9597	0.2299	0.8942	0.9273	0.7967
	3	0.9999	0.5028	1.0000	0.3465	0.9993	0.9997	0.9931

## CHAPITRE 6

## ASYMPTOTIC POWER OF TESTS OF NORMALITY UNDER LOCAL ALTERNATIVES

## 6.1 Introduction

Due mainly to its mathematical tractability, the univariate normal distribution is the base to many statistical models. Then the question rises to know wether a random sample can be considered to be drawn from a population whose density is of the form

$$\phi_{\mu,\sigma}(x) = \frac{1}{\sqrt{2\pi\sigma}} \exp\left\{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2\right\}, \quad x \in \mathbb{R},$$

for some  $(\mu, \sigma) \in \mathbb{R} \times \mathbb{R}^+$ . If f denotes the density of a given population, then the hypotheses of normality are  $\mathcal{H}_0: f(x) = \phi_{\mu,\sigma}(x)$  and  $\mathcal{H}_1: f(x) \neq \phi_{\mu,\sigma}(x)$ for at least one  $x \in \mathbb{R}$ , where  $\mu$  and  $\sigma$  are left unspecified.

Many procedures exist to decide on the acceptance or rejection of  $\mathcal{H}_0$ . The first contribution seems to date back to Geary (1947), where the ratio of

the absolute mean and standard deviation is considered as a criteria to assess normality. This test is formally described by Gel et al. (2007). Other methods are based on the empirical versions of skewness and kurtosis. While each of these two statistics can be used for inferential purposes, the idea of D'Agostino & Pearson (1973) was to combine them. The resulting procedure is often referred to the Jarque–Bera test, which has been later popularized by Jarque & Bera (1980, 1987). Finally, an important family of tests is composed of the functionals of the empirical process with estimated parameters, considered in a general setting by Durbin (1973). The Cramér–von Mises, Anderson–Darling and Kolmogorov–Smirnov procedures are members of this class.

In order for a statistician to choose a suitable method among the available tests, it is crucial to study their power under alternative hypotheses. This has been done by several authors, including Shapiro et al. (1968), Stephens (1974) and Pearson et al. (1977). However, many of these studies consider hypotheses that are so far away from normality that even a simple look at an histogram would lead to the rejection of  $\mathcal{H}_0$ . Furthermore, as mentioned by Durio & Nikitin (2003), many power investigations for goodness-of-fit tests are based on location-scale alternatives, which does not cover the wide range of possible departures from the null hypothesis.

If one admits that a desirable property of a statistical procedure is its ability to reject the null hypothesis under small departures from  $\mathcal{H}_0$ , so-called *local alternatives* must be considered. These alternatives enable to study both the small sample and asymptotic efficiency of tests for normality. Some attempts have been made to compute some kinds of asymptotic relative efficiencies, but the latter are generally based on Bahadur's approach. Although elegant formulas can be discovered from this method, the results are difficult to interpret and hardly relate to daily practice since one considers the power of the tests as the size  $\alpha \to 0$ .

Using the asymptotic theory of van der Vaart & Wellner (1996) and repeated applications of Lecam's third lemma, explicit representations of seven statistics for normality will be obtained under local sequences of distributions. This will enable the comparison of the tests via their local power functions and in the light of an asymptotic relative efficiency measure recently proposed by Berg & Quessy (2009). As will be seen, the conclusions and recommandations that one can extract from these asymptotic investigations can be linked directly to real-world situations, i.e. in cases of small and moderate sample sizes.

The paper is organized as follows. In section 2, the seven tests under investigation are introduced. In section 3, their asymptotic distributions under a general class of local alternatives are obtained. These results are used, in section 4, to characterize the large sample behavior of the tests under three kinds of local alternatives. In section 5, formulas to compute local power curves and asymptotic relative efficiencies are given and comparisons among the seven tests based on these tools are made in section 6. Relationships with power results obtained from a Monte–Carlo simulation for small and moderate sample sizes are described in section 7.

## 6.2 Test statistics for non-normality

In this section, the test statistics whose efficiencies will be analyzed later are presented. These procedures are suitable for the composite null hypothesis  $\mathcal{H}_0$ :  $f = \phi_{\mu,\sigma}$ , where  $(\mu, \sigma)$  are unspecified. From a random sample  $X_1, \ldots, X_n$ , the latter are estimated by the sample mean and variance, namely

$$\hat{\mu} = \frac{1}{n} \sum_{i=1}^{n} X_i$$
 and  $\hat{\sigma}^2 = \frac{1}{n-1} \sum_{i=1}^{n} (X_i - \hat{\mu})^2$ .

Note that all the tests that are described next are invariant with respect to  $\mu$  and  $\sigma$  since they are based on the normalized pseudo-observations

$$\hat{X}_{i,n} = \frac{X_i - \hat{\mu}}{\hat{\sigma}} \,.$$

#### 6.2.1 Tests based on sample skewness and kurtosis

For  $k \ge 2$ , let  $\mu_k$  denote the population's k-th central moment, i.e.  $\mu_k = E\{(X - EX)^k\}$ . The skewness and kurtosis measures are defined respectively by  $\beta_1 = \mu_3/\sigma^3$  and  $\beta_2 = \mu_4/\sigma^4$ . Their natural estimators are

$$\hat{\beta}_1 = \frac{1}{n} \sum_{i=1}^n \left( \frac{X_i - \hat{\mu}}{\hat{\sigma}} \right)^3 = \frac{1}{n} \sum_{i=1}^n \hat{X}_{i,n}^3$$

and

$$\hat{\beta}_2 = \frac{1}{n} \sum_{i=1}^n \left( \frac{X_i - \hat{\mu}}{\hat{\sigma}} \right)^4 = \frac{1}{n} \sum_{i=1}^n \hat{X}_{i,n}^4.$$

When the observations are drawn from a population whose density belongs to the normal family, it is well-established that  $\sqrt{n\hat{\beta}_1} \rightsquigarrow \mathcal{N}(0,6), \sqrt{n}(\hat{\beta}_2-3) \rightsquigarrow \mathcal{N}(0,24)$  and the latter are independent. Here and in the sequel,  $\rightsquigarrow$  means convergence in distribution. Simple tests of normality are then based on the normalized versions

$$S_n = \frac{\sqrt{n}\hat{\beta}_1}{\sqrt{6}}$$
 and  $K_n = \frac{\sqrt{n}\left(\hat{\beta}_2 - 3\right)}{\sqrt{24}}$ .

Specifically, procedures based on the asymptotic distributions would reject  $\mathcal{H}_0$  whenever

$$S_n > \Phi^{-1}\left(1 - \frac{\alpha}{2}\right)$$
 or  $K_n > \Phi^{-1}\left(1 - \frac{\alpha}{2}\right)$ ,

where  $\Phi$  is the cdf of the standard normal distribution.

A potentially more efficient test could emerge if one considers a combination of both  $S_n$  and  $K_n$ . This is the idea behind the Jarque-Bera test statistic, popularized by Jarque & Bera (1980, 1987). The test statistic, which has been originally proposed by D'Agostino & Pearson (1973), is simply

$$JB_n = S_n^2 + K_n^2$$

Bowman & Shenton (1975) used the fact that  $JB_n$  is the sum of two asymptotically independent standardized normals to deduce that  $JB_n \rightsquigarrow \chi_2^2$  under the null hypothesis of normality. Thus, a test based on this asymptotic result leads to the rejection of  $\mathcal{H}_0$  if  $JB_n > \chi_{2,\alpha}^2$ , where  $\chi_{2,\alpha}^2$  is the  $\alpha$ -th percentile of the  $\chi_2^2$  distribution. As noted by many authors, however, the rate of convergence of  $JB_n$  toward its asymptotic distribution is very slow, which prevent from using  $\chi_{2,\alpha}^2$  as a critical value when the sample size is small or moderate. It is better to use estimated critical values in that case.

#### 6.2.2 The test of Gel et al. (2007)

This test is based on the ratio of two estimators of the standard deviation in the normal model. Specifically, the test statistic is

$$\mathbf{R}_n = \sqrt{n} \left( \frac{\hat{\sigma}}{\tilde{\sigma}} - 1 \right),$$

where  $\tilde{\sigma} = \sqrt{\pi/2} n^{-1} \sum_{i=1}^{n} |X_i - \hat{\mu}|$ . An alternate definition is

$$\mathbf{R}_n = \sqrt{n} \left( \frac{1}{\tilde{\sigma}^{\star}} - 1 \right), \quad \text{where } \sigma^{\star} = \sqrt{\pi/2} \, \frac{1}{n} \sum_{i=1}^n \left| \hat{X}_{i,n} \right|,$$

which emphasizes on the fact that  $R_n$  is based on the normalized observations. Under the null hypothesis of normality, Gel et al. (2007) showed that  $R_n \rightsquigarrow \mathcal{N}(0, \sigma_R^2)$ , where  $\sigma_R^2 = (\pi - 3)/2$ . Thus,  $\mathcal{H}_0$  is rejected whenever

$$\frac{|\mathbf{R}_n|}{\sigma_{\mathbf{R}}} > \Phi^{-1} \left( 1 - \frac{\alpha}{2} \right).$$

## 6.2.3 Functionals of an empirical goodness-of-fit process

First define the pseudo-observations

$$\hat{T}_{i,n} = \Phi\left(\frac{X_i - \hat{\mu}}{\hat{\sigma}}\right) = \Phi\left(\hat{X}_{i,n}\right), \quad 1 \le i \le n.$$

If  $X \sim \mathcal{N}(\mu, \sigma^2)$ , then  $T = \Phi\{(X - \mu)/\sigma\}$  follows a standard uniform distribution. It is thus natural to base a test on the empirical goodness-of-fit process

$$\mathbb{F}_n(t) = \frac{1}{\sqrt{n}} \sum_{i=1}^n \left\{ \mathbb{I}\left(\hat{T}_{i,n} \le t\right) - t \right\}.$$

This process was first considered by Durbin (1973), where its asymptotic behavior is established under a quite general setting. The result is recalled here under lemma 6.1 in the special case of normality. An alternate proof of this result using the theory of empirical processes for pseudo-observations due to Ghoudi & Rémillard (1998) is given.

Lemme 6.1. Under  $\mathcal{H}_0$ ,

$$\mathbb{F}_n(t) \rightsquigarrow \mathbb{F}_0(t) = \beta(t) + \phi \left\{ \Phi^{-1}(t) \right\} \left\{ W_1 + \Phi^{-1}(t) \frac{W_2}{\sqrt{2}} \right\},\$$

where  $\beta$  is a brownian bridge, i.e. a continuous and centered Gaussian process with  $E\{\beta(s)\beta(t)\} = min(s,t) - st$  and  $W_1$ ,  $W_2$  are independent  $\mathcal{N}(0,1)$  random variables.

**Proof.** In order to follow the notation of Ghoudi & Rémillard (1998), let

$$H_n(x) = \Phi\left(\frac{x-\hat{\mu}}{\hat{\sigma}}\right)$$
 and  $H(x) = \Phi\left(\frac{x-\mu}{\sigma}\right)$ ,

so that

$$\mathbb{F}_n(t) = \frac{1}{\sqrt{n}} \sum_{i=1}^n \left[ \mathbb{I}\left\{ H_n(X_i) \le t \right\} - K(t) \right],$$

where  $K(t) = P \{H(X) \le t\} = t$ . From classical arguments in the theory of empirical processes,

$$\beta_n(t) = \frac{1}{\sqrt{n}} \sum_{i=1}^n \left[ \mathbb{I} \left\{ H(X_i) \le t \right\} - K(t) \right]$$

converges to a standard brownian bridge  $\beta$ . Also, it is easy to show that  $\mathbb{H}_n(x) = \sqrt{n} \{H_n(x) - H(x)\}$  converges to

$$\mathbb{H}(x) = -\phi\left(\frac{x-\mu}{\sigma}\right)\left\{W_1 + \left(\frac{x-\mu}{\sigma}\right)\frac{W_2}{\sqrt{2}}\right\},\,$$

where  $W_1$ ,  $W_2$  are independent  $\mathcal{N}(0,1)$  random variables. Thus

$$\mu_t(\mathbb{H}) = \mathbb{E} \left\{ \mathbb{H}(X) \, | \, H(X) = t \right\} = -\phi \left\{ \Phi^{-1}(t) \right\} \left\{ W_1 + \Phi^{-1}(t) \frac{W_2}{\sqrt{2}} \right\}.$$

Theorem 2.1 of Ghoudi & Rémillard (1998) implies that  $\mathbb{F}_n(t) \rightsquigarrow \beta(t) - \mu_t(\mathbb{H})$ , which can be seen to be of the announced form.

From this result, one obtains that the limiting covariance function of  $\mathbb{F}_n$  is

$$\mathbb{E}\left\{\mathbb{F}_{0}(s)\mathbb{F}_{0}(t)\right\} = \min(s,t) - st - \phi\left\{\Phi^{-1}(s)\right\}\phi\left\{\Phi^{-1}(t)\right\}\left\{1 + \frac{\Phi^{-1}(s)\Phi^{-1}(t)}{2}\right\},$$

which is exactly the expression that one can deduce from Durbin et al. (1975). One can see that the limit is free of  $\mu$  and  $\sigma$ . As noted by Durbin (1973), this is the case under any location/scale families.

Three popular test statistics that can be written as functionals of  $\mathbb{F}_n$  will be considered in the sequel. They are based on the Cramér-von Mises, Anderson-Darling and Kolmogorov-Smirnov distances, leading to

$$\text{CVM}_n = \int_0^1 \{\mathbb{F}_n(t)\}^2 \, \mathrm{d}t, \quad \text{AD}_n = \int_0^1 \frac{\{\mathbb{F}_n(t)\}^2}{t(1-t)} \, \mathrm{d}t \quad \text{and} \quad \text{KS}_n = \sup_{t \in [0,1]} |\mathbb{F}_n(t)| \, .$$

The fact that the limiting distributions of these statistics do not depend on the unknown mean and variance under  $\mathcal{H}_0$  enables to obtain the critical values of the tests by simple Monte Carlo simulations. These values are presented in table 6.1. For large sample sizes, one can use the asymptotic critical values of  $\text{CVM}_n$  et de  $\text{AD}_n$  obtained by Stephens (1976), namely .126 and .751 respectively. Another possibility is to compute *p*-values from a parametric bootstrap, whose validity in univariate goodness-of-fit testing is established by Jogesh Babu & Rao (2004).

#### 6. Asymptotic power under local alternatives

Table 6.1: Estimation, based on 100 000 replicates, of the 95-th percentile of the distribution of  $S_n$ ,  $K_n$ ,  $JB_n$ ,  $R_n$ ,  $CVM_n$ ,  $AD_n$  and  $KS_n$  under the normality assumption

Test statistics	n = 50	n = 100	n = 250	$n = \infty$
$ S_n $	1.818	1.895	1.926	1.960
$ \mathrm{K}_n $	1.531	1.686	1.818	1.960
$JB_n$	4.516	4.925	5.568	5.992
$ \mathbf{R}_n $	0.531	0.528	0.522	0.522
$\mathrm{CVM}_n$	0.128	0.123	0.126	0.126
$\mathrm{AD}_n$	0.753	0.735	0.750	0.751
$\mathrm{KS}_n$	0.883	0.889	0.898	0.898

**Remark 6.1.** Note that many goodness-of-fit test statistics for normality that have been proposed in the literature are based on the empirical process

$$\tilde{\mathbb{F}}_n(x) = \frac{1}{\sqrt{n}} \sum_{i=1}^n \left\{ \mathbb{I}(X_i \le x) - \Phi\left(\frac{x - \hat{\mu}}{\hat{\sigma}}\right) \right\}.$$

The latter is linked to  $\mathbb{F}_n$  via

$$\tilde{\mathbb{F}}_n(x) = \mathbb{F}_n\left\{\Phi\left(\frac{x-\hat{\mu}}{\hat{\sigma}}\right)\right\} \rightsquigarrow \mathbb{F}_0\left\{\Phi\left(\frac{x-\mu}{\sigma}\right)\right\}.$$

After the simple change of variable  $t = \Phi\{(x - \mu)/\sigma\}$ , one sees that the three statistics based on  $\tilde{\mathbb{F}}_n$  would converge to the same limit.

In the next section, the asymptotic behavior of the seven tests described in this section is investigated under local sequences of alternatives.

# 6.3 Asymptotic behavior of the test statistics under local sequences

Since the test statistics encountered in this paper are invariant with respect to the mean and standard deviation, it can be assumed, without loss of generality, that  $\mu = 0$  and  $\sigma = 1$ . Then local alternatives to  $\mathcal{H}_0$  are characterized by densities  $\ell_{\delta}$  that satisfy

$$\lim_{\delta \to 0} \ell_{\delta}(z) = \phi(z),$$

where  $\phi = \phi_{0,1}$ . It is also assumed that  $\ell_{\delta}$  is not a member of the class of parametric normal densities, otherwise the model would be uninteresting for power investigations. For a fixed  $\delta > 0$ , the power of any consistent test for normality will tend to 1 as the sample size increases. Comparing the asymptotic power of tests for normality would then be irrelevant. A way to circumvent this problem is to consider a sequence of alternatives that is build in such a way that the asymptotic distributions are non-degenerate. Such sequences of densities are those of the form  $(\ell_{\delta/\sqrt{n}})_{n\geq 1}$  that satisfy

$$\lim_{n \to \infty} \int_{\mathbb{R}} \left\{ \sqrt{n} \left( \sqrt{\ell_{\delta/\sqrt{n}}(z)} - \sqrt{\phi(z)} \right) - \frac{\delta \dot{\ell}_0(z)}{2\sqrt{\phi(z)}} \right\}^2 \mathrm{d}z = 0, \tag{6.1}$$

where  $\dot{\ell}_0(z) = \lim_{\delta \to 0} \partial \ell_{\delta}(z) / \partial \delta$ . This criterion, which can be found in van der Vaart & Wellner (1996), ensures that the law induced by  $(\ell_{\delta/\sqrt{n}})_{n\geq 1}$  is contiguous with respect to the law induced by the standard normal distribution. A consequence is that the asymptotic behavior of the test statistics under such sequences can be deduced from that under  $\mathcal{H}_0$ . This is the aim of this section to provide the asymptotic distributions of the seven test statistics under study.

The first result concerns the statistics based on skewness and kurtosis, namely  $S_n$ ,  $K_n$  and  $JB_n$ . To this end, define the k-th local moment by

$$\mu'_k = \int_{\mathbb{R}} z^k \dot{\ell}_0(z) \mathrm{d}z.$$

**Proposition 6.1.** Under a sequence of densities  $(\ell_{\delta/\sqrt{n}})_{n\geq 1}$  that satisfies (6.1),

$$S_n \rightsquigarrow \mathcal{N}\left(\frac{\delta\mu'_3 - 3\delta\mu'_1}{\sqrt{6}}, 1\right), K_n \rightsquigarrow \mathcal{N}\left(\frac{\delta\mu'_4 - 6\delta\mu'_2}{\sqrt{24}}, 1\right) and JB_n \rightsquigarrow \chi^2_2\left(\delta^2\gamma\right),$$

where

$$\gamma = \frac{\left(\mu_3' - 3\mu_1'\right)^2}{6} + \frac{\left(\mu_4' - 6\mu_2'\right)^2}{24} \,.$$

**Proof.** If one assumes without loss of generality that  $\mu = 0$  and  $\sigma = 1$ , one obtains that  $S_n$  and  $K_n$  have the asymptotic representations

$$S_n = \frac{1}{\sqrt{n}} \sum_{i=1}^n \left( \frac{X_i^3 - 3X_i}{\sqrt{6}} \right) + o_P(1) \text{ and } K_n = \frac{1}{\sqrt{n}} \sum_{i=1}^n \left( \frac{X_i^4 - 6X_i^2 + 3}{\sqrt{24}} \right) + o_P(1).$$

under the null hypothesis of normality. From the bivariate central limit theorem,  $(S_n, K_n)$  converges in law, under  $\mathcal{H}_0$ , to a standard bivariate normal distribution. On the other side, condition (6.1) implies

$$L_n = \log \frac{\ell_{\delta/\sqrt{n}}(\mathbf{X})}{\phi(\mathbf{X})} = \frac{\delta}{\sqrt{n}} \sum_{i=1}^n \frac{\dot{\ell}_0(X_i)}{\phi(X_i)} + \frac{\delta^2}{2n} \sum_{i=1}^n \left\{ \frac{\ddot{\ell}_0(X_i)}{\phi(X_i)} - \left(\frac{\dot{\ell}_0(X_i)}{\phi(X_i)}\right)^2 \right\} + o_{\mathrm{P}}(1),$$
(6.2)

where  $\mathbf{X} = (X_1, \ldots, X_n)$ . Hence, the multivariate central limit theorem enables to establish that  $(S_n, K_n, L_n)$  converges in law to a normal distribution with mean (0, 0, 0)' and covariance matrix

$$\Sigma_{\mathrm{S,K},L} = \begin{pmatrix} 1 & 0 & \frac{\delta(\mu'_3 - 3\mu'_1)}{\sqrt{6}} \\ 0 & 1 & \frac{\delta(\mu'_4 - 6\mu'_2)}{\sqrt{24}} \\ \frac{\delta(\mu'_3 - 3\mu'_1)}{\sqrt{6}} & \frac{\delta(\mu'_4 - 6\mu'_2)}{\sqrt{24}} & \sigma_L^2 \end{pmatrix}$$

An application of Lecam's third lemma yields that under the sequence of alternatives  $(\ell_{\delta/\sqrt{n}})$ , the pair  $(S_n, K_n)$  converges in law to a bivariate normal distribution with mean vector  $\delta((\mu'_3 - 3\mu'_1)/\sqrt{6}, (\mu'_4 - 6\mu'_2)/\sqrt{24})'$  and covariance matrix diag(1, 1). The consequences are immediate on  $S_n$ ,  $K_n$  and  $JB_n = S_n^2 + K_n^2$ .

Now the result of Gel et al. (2007) about the asymptotic behavior of  $R_n$  is generalized to the case of contiguous alternatives.

**Proposition 6.2.** Under a sequence of densities  $(\ell_{\delta/\sqrt{n}})_{n\geq 1}$  that satisfies (6.1),

$$\mathbf{R}_n \rightsquigarrow \mathcal{N}\left(\frac{\delta(\mu'_2 - \tilde{\mu}'_2)}{2}, \sigma_{\mathbf{R}}^2\right),$$

where

$$\tilde{\mu}_2' = \sqrt{\frac{2}{\pi}} \int_{\mathbb{R}} |z| \dot{\ell}_0(z) \, \mathrm{d}z.$$

**Proof.** Assuming, without loss of generality, that  $\mu = 0$  and  $\sigma = 1$ , one has

$$\sqrt{n}\tilde{\sigma} = \frac{1}{\sqrt{n}}\sum_{i=1}^{n} \left(\sqrt{\frac{\pi}{2}} |X_i| - 1\right) + o_{\mathsf{P}}(1)$$

#### 6. Asymptotic power under local alternatives

and

$$\sqrt{n}\hat{\sigma} = \frac{1}{2\sqrt{n}}\sum_{i=1}^{n} \left(X_i^2 - 1\right) + o_{\mathsf{P}}(1).$$

Since  $\tilde{\sigma}$  converges in probability to 1, Slutsky's lemma implies that

$$R_n = \sqrt{n} \left( \hat{\sigma} - \tilde{\sigma} \right) + o_P(1) = \frac{1}{2\sqrt{n}} \sum_{i=1}^n \left( 1 + X_i^2 - \sqrt{2\pi} |X_i| \right) + o_P(1).$$

Lecam's third lemma and equation (6.2) entails that  $R_n$  converges in law to a normal distribution with variance  $\sigma_R^2$  and mean

$$\operatorname{cov}\left\{\frac{1+X^2-\sqrt{2\pi}|X|}{2}, \frac{\delta\dot{\ell}_0(X)}{\phi(X)}\right\} = \frac{\delta}{2} \int_{\mathbb{R}} \left(1+x^2-\sqrt{2\pi}|x|\right)\dot{\ell}_0(x)\mathrm{d}x$$
$$= \frac{\delta}{2} \left\{\int_{\mathbb{R}} x^2\dot{\ell}_0(x)\mathrm{d}x - \sqrt{2\pi} \int_{\mathbb{R}} |x|\dot{\ell}_0(x)\mathrm{d}x\right\}$$
$$= \frac{\delta}{2} \left(\mu'_2 - \tilde{\mu}'_2\right),$$

as claimed.

The asymptotic behavior of the empirical goodness-of-fit process  $\mathbb{F}_n$  under sequences of local distributions is described next. Durbin (1973) obtained the result under another set of conditions and local alternatives. A similar result is to be found in Durbin et al. (1975).

**Proposition 6.3.** Under a sequence of densities  $(\ell_{\delta/\sqrt{n}})_{n\geq 1}$  that satisfies (6.1),

$$\mathbb{F}_n(t) \rightsquigarrow \mathbb{F}_0(t) + \delta \,\xi(t),$$

where

$$\xi(t) = \dot{\mathcal{L}}_0 \left\{ \Phi^{-1}(t) \right\} + \phi \left\{ \Phi^{-1}(t) \right\} \left( \mu_1' + \frac{\mu_2' \Phi^{-1}(t)}{2} \right)$$

and

$$\dot{\mathcal{L}}_0(z) = \int_{(-\infty,z]} \dot{\ell}_0(s) \mathrm{d}s.$$

As a consequence,

$$CVM_n \quad \rightsquigarrow \quad \int_0^1 \left\{ \mathbb{F}_0(t) + \delta\xi(t) \right\}^2 \, \mathrm{d}t,$$
$$AD_n \quad \rightsquigarrow \quad \int_0^1 \frac{\left\{ \mathbb{F}_0(t) + \delta\xi(t) \right\}^2}{t(1-t)} \, \mathrm{d}t,$$

$$\operatorname{KS}_n \rightsquigarrow \sup_{t \in [0,1]} |\mathbb{F}_0(t) + \delta \xi(t)|.$$

**Proof.** Recall that without loss of generality, one can assume that  $\mu = 0$  and  $\sigma = 1$ . Note that  $\mathbb{F}_n(t) = \tilde{\mathbb{F}}_n \{ \Phi^{-1}(\hat{\sigma}t + \hat{\mu}) \}$ , where  $\tilde{\mathbb{F}}_n(x) = \tilde{\mathbb{F}}_{n1}(x) - \tilde{\mathbb{F}}_{n2}(x)$ , with

$$\tilde{\mathbb{F}}_{n1}(x) = \frac{1}{\sqrt{n}} \sum_{i=1}^{n} \left\{ \mathbb{I}\left(X_i \le x\right) - \Phi(x) \right\}, \quad \tilde{\mathbb{F}}_{n2}(x) = \sqrt{n} \left\{ \Phi\left(\frac{x - \hat{\mu}}{\hat{\sigma}}\right) - \Phi(x) \right\}.$$

From van der Vaart & Wellner (1996),  $\tilde{\mathbb{F}}_{n1}(x) \rightsquigarrow \tilde{\mathbb{F}}_1(x) = \beta \{\Phi(x)\} + \delta \dot{\mathcal{L}}_0(x)$ , where  $\dot{\mathcal{L}}_0(x) = \int_{-\infty}^x \dot{\ell}_0(s) \, \mathrm{d}s$ . Next, note that  $\tilde{\mathbb{F}}_{n2}$  is asymptotically equivalent to  $-\phi(x) \left( W_{n1} + x W_{n2}/\sqrt{2} \right)$ , where

$$W_{n1} = \sqrt{n} \, \frac{\hat{\mu}}{\hat{\sigma}} = \frac{1}{\sqrt{n}} \sum_{i=1}^{n} X_i + o_{\mathsf{P}}(1),$$
  

$$W_{n2} = \sqrt{2n} \, (\hat{\sigma} - 1) = \frac{1}{\sqrt{n}} \sum_{i=1}^{n} \left( \frac{X_i^2 - 1}{\sqrt{2}} \right) + o_{\mathsf{P}}(1).$$

Equation (6.2) combined with Lecam's third lemma yield  $W_{n1} \rightsquigarrow W_1 + \delta \mu'_1$ and  $W_{n2} \rightsquigarrow W_2 + \delta \mu'_2 / \sqrt{2}$ , so that

$$\tilde{\mathbb{F}}_{n2}(x) \rightsquigarrow \tilde{\mathbb{F}}_{2}(x) = -\phi(x) \left( W_{1} + \frac{xW_{2}}{\sqrt{2}} \right) - \delta\phi(x) \left( \mu_{1}' + \frac{x\mu_{2}'}{2} \right).$$

Since  $\sup_{0 \le t \le 1} |\Phi^{-1}(\hat{\sigma}t + \hat{\mu}) - \Phi^{-1}(t)|$  converges in probability to 0, the result follows from  $\mathbb{F}_n(t) = \tilde{\mathbb{F}}_n\{\Phi^{-1}(\hat{\sigma}t + \hat{\mu})\} \rightsquigarrow \tilde{\mathbb{F}}_1\{\Phi^{-1}(t)\} - \tilde{\mathbb{F}}_2\{\Phi^{-1}(t)\}.$ 

Durbin et al. (1975) obtained the asymptotic representations of  $\text{CVM}_n$  and  $\text{AD}_n$  in terms of a weighted sum of non-central chi-square random variables. They were generalizing an earlier result of Durbin & Knott (1972) in the case when  $\mu$  and  $\sigma$  are specified. The types of alternatives used by Durbin et al. (1975) are however of a complicated form and are difficult to interpret.

Propositions 6.1, 6.2 and 6.3 give the general representations of the seven statistics under sequences of densities that satisfy assumption (6.1). In the next section, three such models are considered for which explicit formulas are given for their asymptotic representations.

### 6.4 Three kinds of local alternatives

In this section, three families of alternatives to the normal distribution will be introduced. In all cases, the associated densities are mixtures of the form  $\ell_{\delta}(z) = (1 - \delta)\phi(z) + \delta h(z)$ , where h is a density. It is then clear that  $\lim_{\delta \to 0} \ell_{\delta}(z) = \phi(z)$ . It is easy to compute that  $\dot{\ell}_0(z) = h(z) - \phi(z)$ . Hence,  $\dot{\mathcal{L}}_0(z) = H(z) - \Phi(z)$ , where H is the cdf associated to h. Moreover,  $\mu'_k = \mathrm{E}(Y^k) - \mathrm{E}(Z^k)$  and  $\tilde{\mu}'_2 = \sqrt{2\pi}\mathrm{E}|Y| - 2$ , where  $Y \sim h$  and  $Z \sim \phi$ . The three models that will be considered in the sequel are

 $\mathcal{A}_1$ . bimodal alternatives :  $h(z) = \phi(x - \mu), \mu > 0$ ;

 $\mathcal{A}_2$ . kurtosis alternatives :  $h(z) = (1/\sigma)\phi(x/\sigma), \ \sigma > 1$ ;

 $\mathcal{A}_3$ . Heavy-tailed alternatives :  $h(z) = \phi(z)\mathbb{I}(z < 0) + g_{\nu}(z)\mathbb{I}(z \ge 0)$ , where  $g_{\nu}$  is Student's density with  $\nu$  degrees of freedom.

The alternatives (1) and (2) have been used by Thadewald & Büning (2007) to study the power of some tests of normality in small samples. The local alternatives (3) have tails that are heavier than that of the normal distribution.

A corollary to propositions 6.1, 6.2 and 6.3 is now given for the class  $A_1$  of models. Obviously, the drift terms, i.e. those who appears in the asymptotic distributions as a consequence of contiguity, vanish whenever  $\mu = 0$ .

**Corollaire 6.1.** Under the sequence of alternatives  $A_1$ ,

(i) 
$$S_n \rightsquigarrow \mathcal{N}\left(\frac{\delta\mu^3}{\sqrt{6}}, 1\right)$$
,  $K_n \rightsquigarrow \mathcal{N}\left(\frac{\delta\mu^4}{\sqrt{24}}, 1\right)$  and  $JB_n \rightsquigarrow \chi_2^2(\delta^2\gamma)$ , where  
 $\gamma = \mu^6(\mu^2 + 4)/24;$   
(ii)  $R_n \rightsquigarrow \mathcal{N}(\delta a(\mu), \sigma_R^2)$ , where  $a(\mu) = \frac{\mu^2}{2} + \sqrt{\frac{\pi}{2}} \mu + 1 - \sqrt{2\pi} \{\mu \Phi(\mu) + \phi(\mu)\};$   
(iii)  $\mathbb{F}_n(t) \rightsquigarrow \mathbb{F}_0(t) + \delta \left[\Phi\left\{\Phi^{-1}(t) - \mu\right\} - t + \phi\left\{\Phi^{-1}(t)\right\}\left\{\mu + \frac{\mu^2 \Phi^{-1}(t)}{2}\right\}\right].$ 

**Proof.** Let  $Y \sim \phi(z - \mu)$ , so that Y is equal in distribution to  $Z + \mu$ , where  $Z \sim \phi$ . Hence,  $\mu'_k = \mathbb{E}\{(Z + \mu)^k - Z^k\}$ . Straightforward computations yield
#### 6. Asymptotic power under local alternatives

$$\begin{split} \mu_1' &= \mu, \, \mu_2' = \mu^2, \, \mu_3' = \mu(\mu^2 + 3) \text{ and } \mu_4' = \mu^2(\mu^2 + 6). \text{ Moreover,} \\ \mathbf{E} \left| Z + \mu \right| &= \int_{-\infty}^{\infty} \left| z + \mu \right| \phi(z) \mathrm{d}z \\ &= -\int_{-\infty}^{-\mu} (z + \mu) \phi(z) \mathrm{d}z + \int_{-\mu}^{\infty} (z + \mu) \phi(z) \mathrm{d}z \\ &= -\int_{-\infty}^{-\mu} \phi'(z) \mathrm{d}z - \mu \int_{-\infty}^{-\mu} \phi(z) \mathrm{d}z - \int_{-\mu}^{\infty} \phi'(z) \mathrm{d}z + \mu \int_{-\mu}^{\infty} \phi(z) \mathrm{d}z \\ &= 2\phi(\mu) + \mu \left\{ 2\Phi(\mu) - 1 \right\}, \end{split}$$

so that  $\tilde{\mu}'_2 = 2\sqrt{2\pi}\phi(\mu) + \sqrt{2\pi}\mu\{2\Phi(\mu) - 1\} - 2.$ 

The next corollary is an analog to corollary 6.1 for the class  $\mathcal{A}_2$ .

**Corollaire 6.2.** Under the sequence of alternatives  $A_2$ ,

(i) 
$$S_n \rightsquigarrow \mathcal{N}(0, 1), K_n \rightsquigarrow \mathcal{N}\left(\frac{\delta(\sigma^2 - 1)^2}{\sqrt{8/3}}, 1\right)$$
 and  $JB_n \rightsquigarrow \chi_2^2(\delta^2\gamma)$ , where  
 $\gamma = 3(\sigma^2 - 1)^4/8;$   
(ii)  $R_n \rightsquigarrow \mathcal{N}\left(\frac{\delta(\sigma - 1)^2}{2}, \sigma_R^2\right);$   
(iii)  $\mathbb{F}_n(t) \rightsquigarrow \mathbb{F}_0(t) + \delta\left[\Phi\left\{\frac{\Phi^{-1}(t)}{\sigma}\right\} - t + \left(\frac{\sigma^2 - 1}{2}\right)\phi\left\{\Phi^{-1}(t)\right\}\Phi^{-1}(t)\right].$   
**Proof** First of all  $u' = \mathbb{E}\left[(\sigma Z)^k - Z^k\right] = (\sigma^k - 1)\mathbb{E}(Z^k)$  Hence  $u' = \mathbb{E}\left[(\sigma Z)^k - Z^k\right]$ 

**Proof.** First of all,  $\mu'_k = E\{(\sigma Z)^k - Z^k\} = (\sigma^k - 1)E(Z^k)$ . Hence,  $\mu'_1 = \mu'_3 = 0$ ,  $\mu'_2 = \sigma^2 - 1$  and  $\mu'_4 = 3(\sigma^4 - 1)$ . Also,  $\tilde{\mu}'_2 = \sqrt{2\pi}E|\sigma Z| - 2 = 2(\sigma - 1)$ .

The fact that  $S_n$ , under local sequences of the type  $\mathcal{A}_2$ , has the same asymptotic distribution as under  $\mathcal{H}_0$  is noteworthy. This is easily explained by the fact that the alternatives are symmetric.

**Corollaire 6.3.** Under the sequence of alternatives  $A_3$ ,

#### 6. Asymptotic power under local alternatives

(i)  $S_n \rightsquigarrow \mathcal{N}(\delta a_1(\nu), 1), K_n \rightsquigarrow \mathcal{N}(a_2(\nu), \delta, 1) \text{ and } JB_n \rightsquigarrow \chi^2_2(\delta^2 \gamma), \text{ where }$ 

$$a_1(\nu) = \frac{\sqrt{\nu}(9-\nu)\Gamma\left(\frac{\nu-3}{2}\right)}{4\sqrt{\pi}\Gamma\left(\frac{\nu}{2}\right)} + \frac{1}{\sqrt{2\pi}}, \quad a_2(\nu) = \frac{3(\nu+4)}{(\nu-2)(\nu-4)}$$

and  $\gamma = a_1^2(\nu) + a_2^2(\nu);$ 

(*ii*) 
$$R_n \rightsquigarrow \mathcal{N}(\delta a_3(\nu), \sigma_R^2)$$
, where  $a_3(\nu) = \frac{1}{2} \left\{ \frac{1}{\nu - 2} - \frac{\sqrt{\nu} \Gamma\left(\frac{\nu - 1}{2}\right)}{2\sqrt{\pi} \Gamma\left(\frac{\nu}{2}\right)} + \frac{1}{\sqrt{2\pi}} \right\};$   
(*iii*)  $\mathbb{F}_n(t) \rightsquigarrow \mathbb{F}_0(t) + \delta \left[ G_{\nu} \left\{ \Phi^{-1}(t) \right\} - t \right] \mathbb{I}(t \ge 1/2) - \delta \phi \left\{ \Phi^{-1}(t) \right\} \left\{ \frac{\sqrt{\nu} \Gamma\left(\frac{\nu - 1}{2}\right)}{2\sqrt{\pi} \Gamma\left(\frac{\nu}{2}\right)} - \frac{1}{\sqrt{2\pi}} + \frac{1}{2(\nu - 2)} \Phi^{-1}(t) \right\}.$ 

**Proof.** First note that  $\dot{\ell}_0(z) = \{g_\nu(z) - \phi(z)\}\mathbb{I}(z \ge 0)$ . Then, from wellknown results about the moments of the Student distribution that one can find, for example, in Casella & Berger (1990), one computes

$$\mu_{k}^{\prime} = \begin{cases} \frac{\nu^{1/2} \Gamma\left(\frac{\nu-1}{2}\right)}{2\sqrt{\pi} \Gamma\left(\frac{\nu}{2}\right)} - \frac{1}{\sqrt{2\pi}}, & k = 1; \\\\ \frac{1}{\nu-2}, & k = 2 \\\\ \frac{\nu^{3/2} \Gamma\left(\frac{\nu-3}{2}\right)}{2\sqrt{\pi} \Gamma\left(\frac{\nu}{2}\right)} - \sqrt{\frac{2}{\pi}}, & k = 3; \\\\ \frac{3(3\nu-4)}{(\nu-2)(\nu-4)}, & k = 4. \end{cases}$$

After straightforward algebra, one finds

$$a_{1}(\nu) = \frac{\mu_{3}' - 3\mu_{1}'}{\sqrt{6}} = \frac{\sqrt{\nu}(9 - \nu)\Gamma\left(\frac{\nu - 3}{2}\right)}{4\sqrt{6\pi} \Gamma\left(\frac{\nu}{2}\right)} + \frac{1}{\sqrt{12\pi}},$$
  
$$a_{2}(\nu) = \frac{\mu_{4}' - 6\mu_{2}'}{\sqrt{24}} = \frac{3(\nu + 4)}{\sqrt{24}(\nu - 2)(\nu - 4)}.$$

Note also that

$$\tilde{\mu}_{2}' = \sqrt{2\pi} \int_{0}^{\infty} z \left\{ g_{\nu}(z) - \phi(z) \right\} dz = \frac{\sqrt{\nu} \Gamma\left(\frac{\nu-1}{2}\right)}{2\sqrt{\pi} \Gamma\left(\frac{\nu}{2}\right)} - \frac{1}{\sqrt{2\pi}} \,.$$

Hence,

$$a_{3}(\nu) = \frac{\mu_{2}' - \tilde{\mu}_{2}'}{2} = \frac{1}{2} \left\{ \frac{1}{\nu - 2} - \frac{\sqrt{\nu} \Gamma\left(\frac{\nu - 1}{2}\right)}{2\sqrt{\pi} \Gamma\left(\frac{\nu}{2}\right)} + \frac{1}{\sqrt{2\pi}} \right\}.$$

In section 6, corollaries 6.1, 6.2 and 6.3 will be used in order to compute the local power functions of the tests. It will then be possible to make comparisons in view of their local efficiencies. Before that, the notions of local power curve and local efficiency, as well as strategies to compute them, will be given. This is the subject of the next section.

### 6.5 Asymptotic power and efficiency

Many attempts have been made to generalize the notion of Pitman's asymptotic relative efficiency outside the asymptotic normality. Rothe (1981), for example, extended the idea to asymptotically chi-squared distributions. It is however unapplicable when dealing with goodness-of-fit procedures based on functionals of empirical processes. Another possibility is to consider the limiting Bahadur efficiency, which was shown by Wieand (1976) to correspond to the limiting Pitman efficiency under certain conditions. This was the approach privileged by Koziol (1986), where the limiting Bahadur efficiency of  $\text{CVM}_n$  and  $\text{AD}_n$  is computed under the local alternatives of Durbin et al. (1975). As mentioned in the introduction, such results are difficult to interpret since one considers the power of the tests as  $\alpha \to 0$ .

The approach that will be employed here is based on local power curves. Let  $W_{n1}$  and  $W_{n2}$  be two test statistics for a given null hypothesis  $\mathcal{H}_0$ . Their local power curves are defined by

$$\beta_i(\delta) = \lim_{n \to \infty} \mathbb{P}\left(\text{the test based upon } W_{ni} \text{ rejects } \mathcal{H}_0 \left| \ell_{\delta/\sqrt{n}} \right), \quad i = 1, 2.$$

The asymptotic relative efficiency measure proposed by Berg & Quessy (2009) is

ARE 
$$(W_{n1}, W_{n2}) = \left(\lim_{M \to \infty} \frac{\int_0^M \{1 - \beta_2(\delta)\} d\delta}{\int_0^M \{1 - \beta_1(\delta)\} d\delta}\right)^2$$
. (6.3)

The first motivation behind this definition is the fact that it generalizes Pitman's notion of ARE when  $W_{n1}$  and  $W_{n2}$  are asymptotically normal. To see this, suppose  $W_i \rightsquigarrow \mathcal{N}(\delta \mu_i, \sigma_i^2)$ , i = 1, 2, under a given local alternative. In that case, the local power curves are

$$\beta_i(\delta) = 1 + \Phi\left(-z_{\alpha/2} - \delta \left|\frac{\mu_i}{\sigma_i}\right|\right) - \Phi\left(z_{\alpha/2} - \delta \left|\frac{\mu_i}{\sigma_i}\right|\right), \quad (6.4)$$

where  $z_{\alpha/2} = \Phi^{-1}(1 - \alpha/2)$ . The proof of the next lemma can be found in Berg & Quessy (2009).

#### 6. Asymptotic power under local alternatives

**Lemme 6.2.** Let  $W_n \rightsquigarrow \mathcal{N}(\delta \mu, \sigma^2)$ . Then

$$\int_0^\infty \left\{ 1 - \beta_W(\delta) \right\} \mathrm{d}\delta = \frac{z_{\alpha/2}}{|\mu/\sigma|}$$

A consequence of lemma 6.2 is that

ARE 
$$(W_{n1}, W_{n2}) = \left(\frac{\mu_2/\sigma_2}{\mu_1/\sigma_1}\right)^2$$

when  $W_{n1}$  and  $W_{n2}$  are asymptotically normal. This is exactly the definition of Pitman's relative efficiency measure.

It is also possible to derive an explicit expression for statistics that are asymptotically non-central chi-squared. The result will be useful to investigate the local power of  $JB_n$ , though it is of an independent interest.

**Lemme 6.3.** Let  $W_n \rightsquigarrow \chi_k^2(\delta^2 \gamma)$ . Denote by  $G(x, \ell)$  the cdf of a central chi-square distribution with  $\ell$  degrees of freedom and  $\chi_{\ell;\alpha}^2$  its corresponding percentile of order  $1 - \alpha$ . Then

$$\beta_{W}(\delta) = 1 - \sum_{j=0}^{\infty} \frac{e^{-\delta^{2}\gamma/2} \left(\delta^{2}\gamma/2\right)^{j}}{j!} G\left(\chi_{k;\alpha}^{2}; 2j+k\right)$$
(6.5)

and

1

$$\int_0^\infty \{1 - \beta_W(\delta)\} \,\mathrm{d}\delta = \frac{1}{\sqrt{2\gamma}} \int_0^{\chi^2_{k;\alpha}/2} e^{-u} \left\{ \sum_{j=0}^\infty \frac{\Gamma(j+1/2) \, u^{j+k/2-1}}{j! \Gamma(j+k/2)} \right\} \,\mathrm{d}u.$$

In particular,

$$\int_0^\infty \left\{ 1 - \beta_W(\delta) \right\} \mathrm{d}\delta = \frac{z_{\alpha/2}}{\sqrt{\gamma}}$$

when k = 1 and

$$\int_0^\infty \{1 - \beta_W(\delta)\} \,\mathrm{d}\delta = \frac{1}{\sqrt{2\gamma}} \int_0^{\chi^2_{2;\alpha}/2} e^{-u} \left\{ \sum_{j=0}^\infty \frac{\Gamma(j+1/2) \, u^j}{j! j!} \right\} \,\mathrm{d}u$$

when k = 2.

#### 6. Asymptotic power under local alternatives

**Proof.** The expression for  $\beta_W$  is standard. Next, since

$$\int_0^\infty e^{-\delta^2 \gamma/2} \left(\delta^2 \gamma/2\right)^j \,\mathrm{d}\delta = \frac{1}{\sqrt{2\gamma}} \int_0^\infty y^{j-1/2} e^{-y} \mathrm{d}y = \frac{1}{\sqrt{2\gamma}} \,\Gamma\left(j+\frac{1}{2}\right),$$

one computes

$$\int_0^\infty \left\{1 - \beta(\delta)\right\} \mathrm{d}\delta = \frac{1}{\sqrt{2\gamma}} \sum_{j=0}^\infty \frac{\Gamma\left(j + \frac{1}{2}\right)}{j!} G\left(\chi_{k;\alpha}^2; 2j + k\right).$$

Using the fact that

$$G(x;2j+k) = \int_0^x \frac{y^{j+k/2-1}e^{-y/2}}{\Gamma(j+k/2)2^{j+k/2}} \mathrm{d}y = \int_0^{x/2} \frac{u^{j+k/2-1}e^{-u}}{\Gamma(j+k/2)} \,\mathrm{d}u,$$

one obtains the result after straightforward computations.

Note that the preceding result is in accordance with lemma 6.2 when k = 1since in that case,  $W_n \rightsquigarrow \chi_1^2(\delta^2 \gamma) \equiv X^2$ , where  $X \sim \mathcal{N}(\delta \sqrt{\gamma}, 1)$ . Moreover, lemma 6.3 enables to obtain that  $ARE(W_{n1}, W_{n2}) = \gamma_2/\gamma_1$  when  $W_{ni} \rightsquigarrow \chi_k^2(\delta^2 \gamma_i)$ , i = 1, 2. This result can then be used to compare the asymptotic relative efficiency of testing procedures that converge to the chi-squared distribution with the same number of degrees of freedom.

It does not seem possible to obtain an explicit expression for  $\int_0^\infty \{1 - \beta(\delta)\} d\delta$ when  $\beta$  is the local power curve of either  $\text{CVM}_n$ ,  $\text{AD}_n$  or  $\text{KS}_n$ . An approximate numerical method is then needed. Since  $\mathbb{F}_n(t) \rightsquigarrow \mathbb{F}_0(t) + \delta\xi(t)$  under a local sequence that satisfies (6.1), one can estimate the limit of  $\mathbb{F}_n$  by  $\hat{\mathbb{F}}_0(t) + \delta\xi(t)$ , where for a sufficiently large N,

$$\hat{\mathbb{F}}_{0}(t) = \frac{1}{\sqrt{N}} \sum_{i=1}^{N} \left\{ \mathbb{I}\left(\hat{T}_{i,N} \leq t\right) - t \right\},\$$

with  $\hat{T}_{i,N} = \Phi\{(X_i - \bar{X}_N)/S_N\}, X_1, \dots, X_N$  are i.i.d.  $\mathcal{N}(0,1)$  and  $\bar{X}_N, S_N$ are the empirical mean and standard deviation. Replacing  $\mathbb{F}_n$  by  $\hat{\mathbb{F}}_0(t)$  +

 $\delta \xi(t)$  in the expressions for the Cramér–von Mises and Anderson–Darling statistics that one can find in equations (3.4) and (3.6), approximations under contiguity are given by

$$\widehat{\text{CVM}}(\delta) = \frac{1}{M} \sum_{m=1}^{M} \left\{ \widehat{\mathbb{F}}_0\left(\frac{m}{M}\right) + \delta\xi\left(\frac{m}{M}\right) \right\}^2$$

and

$$\widehat{\mathrm{AD}}(\delta) = M \sum_{m=1}^{M} \left\{ \widehat{\mathbb{F}}_0\left(\frac{m}{M}\right) + \delta \xi\left(\frac{m}{M}\right) \right\}^2 / m(M-m),$$

where M has to be chosen arbitrarily large to ensure sufficient accuracy. For the Kolmogorov–Smirnov statistic, a possible approximation is

$$\widehat{\mathrm{KS}}(\delta) = \max_{1 \le m \le M} \left| \widehat{\mathbb{F}}_0\left(\frac{m}{M}\right) + \delta \xi\left(\frac{m}{M}\right) \right|.$$

In order to ease the computations, note that

$$\hat{\mathbb{F}}_{0}\left(\frac{m}{M}\right) = \frac{1}{\sqrt{N}} \sum_{i=1}^{N} \mathbb{I}\left(\hat{T}_{i,N} \leq \frac{m}{M}\right) - \frac{\sqrt{N}m}{M}.$$

Now suppose that for an arbitrary statistic  $W_n$  and a fixed value of  $\delta > 0$ , one has a sample  $\hat{W}^{(1)}(\delta), \ldots, \hat{W}^{(K)}(\delta)$  of observations that are distributed, asymptotically, as the limiting distribution of  $W_n$  under  $(\ell_{\delta/\sqrt{n}})_{n\geq 1}$ . An approximation for the local power curve of  $W_n$  is then given by

$$\hat{\beta}_W(\delta) = \frac{1}{K} \sum_{k=1}^K \mathbb{I}\left\{\hat{W}^{(k)}(\delta) > q_\alpha\right\}.$$
(6.6)

If  $\hat{\beta}_W(i/T)$ ,  $i \in \{1, \ldots, D\}$ , are available, where D is chosen such that  $\hat{\beta}(D/T) = 1$ . An approximation of the asymptotic efficiency at level  $\alpha$  is

#### 6. Asymptotic power under local alternatives

then given by

$$\widehat{AE}(W) = \frac{D}{T} + \frac{1+\alpha}{2T} - \frac{1}{T} \sum_{i=0}^{D} \hat{\beta}_{W}\left(\frac{i}{T}\right).$$
(6.7)

In the next section, these formulas are used to compute the local power curves and the local efficiencies of the tests.

# 6.6 Investigation of the asymptotic efficiency of the seven tests

In this section, comparisons of the asymptotic efficiency of the tests are made using the results of sections 4–5.

#### 6.6.1 Local power curves

Here, the local power curves of the seven test statistics will be compared under models  $\mathcal{A}_1$ ,  $\mathcal{A}_2$  and  $\mathcal{A}_3$ . For the asymptotically normally distributed statistics  $S_n$ ,  $K_n$  and  $R_n$ , these functions are of the form (6.4), while that of JB<sub>n</sub> derives from equation (6.5). For CVM<sub>n</sub>, AD<sub>n</sub> and KS<sub>n</sub>, the curves are obtained from (6.6) with N = 2500, M = 500 and 10 000 replicates.

#### Model $\mathcal{A}_1$

In figure 6.1, the local power curves of the seven tests are presented when  $\mu = 1$  and  $\mu = 2$ . For  $\mu = 1$ , JB<sub>n</sub> and S<sub>n</sub> have very similar local power curves and are the best statistics. They are followed by the three functionals of  $\mathbb{F}_n$  and by K<sub>n</sub>, with a slight advantage to the Anderson-Darling statistics AD<sub>n</sub>. The test based on R<sub>n</sub> has a weak power. For  $\mu = 2$ , the Jarque-Bera test emerges as the best procedure, while S<sub>n</sub> is still a good alternative too. Note the equivalence between K<sub>n</sub> and S<sub>n</sub> in that case. The functionals of  $\mathbb{F}_n$  and the test based on R<sub>n</sub> have quite similar powers, AD<sub>n</sub> being, again, the best among the group.



Figure 6.1: Local power curves of  $S_n$ ,  $K_n$ ,  $JB_n$ ,  $R_n$ ,  $CVM_n$ ,  $AD_n$  and  $KS_n$ under model  $A_1$ . Left panel :  $\mu = 1$ ; right panel :  $\mu = 2$ 

#### Model $\mathcal{A}_2$

In figure 6.2, the local power curves of the seven tests are presented when  $\sigma = 1.5$  and  $\sigma = 2$ . In both situations, the tests based on  $K_n$  and  $JB_n$  are the best choices, with a mild advantage to  $K_n$ . The test statistic  $R_n$  performs rather well, too, especially when  $\sigma$  is small. The test statistics based on functionals of  $\mathbb{F}_n$  are less powerful. Similarly as in model  $\mathcal{A}_1$ ,  $AD_n$  is the best and  $KS_n$  is the worst among the three. Note that  $S_n$  has no power at all since its behavior under these local alternatives is the same as under  $\mathcal{H}_0$ , as stated in corollary 6.2.



Figure 6.2: Local power curves of  $S_n$ ,  $K_n$ ,  $JB_n$ ,  $R_n$ ,  $CVM_n$ ,  $AD_n$  and  $KS_n$ under model  $\mathcal{A}_2$ . Left panel :  $\sigma = 1.5$ ; right panel :  $\sigma = 2$ 

#### Model $\mathcal{A}_3$

In figure 6.3, the local power curves of the seven tests are presented when  $\nu = 5$  and  $\nu = 10$ . When  $\nu = 5$ , the best procedures are those based on

 $K_n$  and  $JB_n$ . The least powerful test statistics are  $CVM_n$  and  $KS_n$ . It is more ambiguous in the case of  $AD_n$ ,  $S_n$  and  $R_n$ . Indeed, while  $S_n$  has a slight advantage over  $R_n$ , the local power curve of the Anderson-Darling statistic outperforms the other two for large values of  $\delta$ . When  $\nu = 10$ , note the surprisingly good performance of  $AD_n$ , especially for large values of  $\delta$ . However, the differences among the seven tests are less notable than for  $\nu = 5$ . The asymptotic relative efficiency computations presented in the next subsection will enable to decide on the more powerful statistic in situations when the local power curves intersect.



Figure 6.3: Local power curves of  $S_n$ ,  $K_n$ ,  $JB_n$ ,  $R_n$ ,  $CVM_n$ ,  $AD_n$  and  $KS_n$ under model  $A_3$ . Left panel :  $\nu = 5$ ; right panel :  $\nu = 10$ 

#### 6.6.2 Relative efficiency

For a given statistic  $W_n$  with an associated local power curve  $\beta_W$ , let  $AE_W = 1/\int_0^\infty \{1 - \beta_W(\delta)\} d\delta$  denote its asymptotic efficiency. The latter intervenes in the definition of asymptotic relative efficiency that one can find in equa-

tion (6.3). The higher  $AE_W$  is, the more powerful a statistic is locally. For  $S_n$ ,  $K_n$ ,  $JB_n$  and  $R_n$ , the asymptotic efficiencies can be readily computed. They can be written as functions of the parameters that appear in models  $\mathcal{A}_1$ ,  $\mathcal{A}_2$  and  $\mathcal{A}_3$ . These relationships are presented in figures 6.4–6.6.

In figure 6.4, the asymptotic efficiencies as a function of  $\mu$  of the four statistics in model  $\mathcal{A}_1$  are presented. The cases  $\mu \in [0, 1]$  and  $\mu \in [1, 3]$  are offered separately since the conclusions differ according to whether  $\mu$  is small or large. For small values of  $\mu$  (left panel),  $S_n$  and  $JB_n$  are the most powerful. In the right panel of figure 6.4, one sees that as  $\mu$  increases,  $S_n$  loses some of its efficiency to the advantage of  $K_n$ , which performs almost as good as the Jarque-Bera test statistic. Finally,  $R_n$  is the least powerful for all values of  $\mu$ . These observations are in agreement with the conclusions drawn from figure 6.1.



Figure 6.4: Asymptotic efficiency of  $S_n$ ,  $K_n$ ,  $JB_n$  and  $R_n$  as a function of  $\mu$  in model  $\mathcal{A}_1$ . Left panel :  $\mu \in [0, 1]$ ; right panel :  $\mu \in [1, 3]$ 

In figure 6.5, one offers the asymptotic efficiencies in model  $A_2$  as a function

of  $\sigma$ . As was noted previously, the statistic  $S_n$  based on skewness has no power, which explains its absence. The test statistic  $K_n$ , based on kurtosis, has the highest asymptotic efficiency, with a slight advantage over  $JB_n$ . This is explained by the fact that  $JB_n$ , apart from being based on  $K_n$ , is also a function of  $S_n$ , which does not contribute to the power. The performance of  $R_n$  is very weak, especially as the alternative moves away from  $\mathcal{H}_0$ , i.e. as  $\sigma$ increases. Again, these conclusions are in perfect agreement with the local power curves presented in figure 6.2.



Figure 6.5: Asymptotic efficiency of  $S_n$ ,  $K_n$ ,  $JB_n$  and  $R_n$  as a function of  $\sigma \in [1,3]$  in model  $\mathcal{A}_2$ 

The asymptotic efficiencies that one can find in figure 6.6 indicate the superiority of JB<sub>n</sub> and K<sub>n</sub> over S<sub>n</sub> and R<sub>n</sub> in model  $\mathcal{A}_3$ , especially for small values of  $\nu$ . Obviously, all efficiencies are decreasing functions of  $\nu$ , since model  $\mathcal{A}_3$ converges to the standard normal as  $\nu \to \infty$ . The decrease in efficiency of R<sub>n</sub> is however slower than for its competitors, so that R<sub>n</sub> exceeds K<sub>n</sub> around  $\nu = 10$ . This is, too, in agreement with figure 6.3.



Figure 6.6: Asymptotic efficiency of  $S_n$ ,  $K_n$ ,  $JB_n$  and  $R_n$  as a function of  $\nu \in [5, 15]$  in model  $\mathcal{A}_3$ 

To close this section, the asymptotic relative efficiency measure of Berg & Quessy (2009) presented in (6.3) is computed for the seven test statistics. This will complement the analyses of the local power curves presented in figures 6.1–6.3. For  $S_n$ ,  $K_n$ ,  $JB_n$  and  $R_n$ , the computations are based on lemma 6.2 and lemma 6.3. For the functionals of the empirical process  $\mathbb{F}_n$ , the asymptotic efficiencies are approximated with formula (6.7). The results are in table 6.2.

Aside from some cases, the Jarque-Bera test statistics is the best procedure. A notable exception is under model  $\mathcal{A}_2$ , where  $K_n$  is about 26% more efficient than JB<sub>n</sub>. One can also note the deceptively low power of CVM<sub>n</sub>, AD<sub>n</sub> and KS<sub>n</sub>. These results give other arguments in favor of the Jarque-Bera test for normality. It also confirms the poor behavior of the functionals of  $\mathbb{F}_n$ .

Table 6.2: Asymptotic relative efficiency of  $S_n$ ,  $K_n$ ,  $R_n$ ,  $CVM_n$ ,  $AD_n$  and  $KS_n$  with respect to the Jarque-Bera test statistic  $JB_n$ 

Model	parameter	Sn	Kn	$\mathbb{R}_n$	$CVM_n$	AD <sub>n</sub>	$KS_n$
$\mathcal{A}_{I}$	$\mu = 1$	1.0109	0.2527	0.1227	0.4404	0.5324	0.3281
$\mathcal{A}_1$	$\mu = 2$	0.6317	0.6317	0.1864	0.2084	0.2781	0.1433
$\mathcal{A}_2$	$\sigma = 1.5$	0.0000	1.2637	0.3046	0.1263	0.1738	0.0731
$\mathcal{A}_2$	$\sigma = 1$	0.0000	1.2639	0.1469	0.0518	0.0741	0.0304
$\mathcal{A}_3$	$\nu = 5$	0.1041	1.1596	0.0806	0.0439	0.0826	0.0302
$\mathcal{A}_3$	$\nu = 10$	0.4709	0.7928	0.7363	0.5806	1.0883	0.4003

### 6.7 Discussion and link with empirical results

In order to complement the asymptotic results presented in the preceding section, a standard Monte-Carlo simulation study has been designed. The results are to be found in tables 6.3–6.5, where the ability of  $S_n$ ,  $K_n$ ,  $JB_n$ ,  $R_n$ ,  $CVM_n$ ,  $AD_n$  and  $KS_n$  to reject the null hypothesis of normality is approximated under mixture distributions of the form  $\mathcal{A}_1$ ,  $\mathcal{A}_2$  and  $\mathcal{A}_3$ . Three sample sizes were considered, namely n = 50,100,250. The approximate critical values of table 6.1 were used. This was particularly necessary for the Jarque-Bera statistics since its convergence toward its asymptotic distribution is very slow.

First of all, it can be said that the empirical powers match the asymptotic results very well. This is particularly true for small values of  $\delta$ , because the asymptotic study considered the mixture parameter  $\delta$  going to infinity at the rate  $1/\sqrt{n}$ . Hence, the conclusions which were stated in section 6 also apply,

to a large extent, to small and moderate sample sizes. Thus, the Jarque-Bera test is the most recommendable, while the functionals of  $\mathbb{F}_n$ , although leading to consistent procedures, are to be avoided.

Some results in tables 6.3–6.5 can be explained from the characteristic of the models considered. For example, note that for the densities in the class  $\mathcal{A}_1$  of models, the central moment of order k is

$$\mathbf{E}(X^k) = (1 - \delta)\mathbf{E}(Z^k) + \delta\mathbf{E}\{(Z + \mu)^k\}.$$

This enables to compute  $E(X) = \delta \mu$ ,  $E(X^2) = 1 + \delta \mu^2$ ,  $E(X^3) = \delta(3\mu + \mu^3)$ and  $E(X^4) = 3 + \delta \mu^2(\mu^2 + 6)$ . Hence,  $var(X) = 1 + \delta(1 - \delta)\mu^2$ ,

$$\beta_1 = \frac{\delta(1-\delta)(1-2\delta)\mu^3}{\{1+\delta(1-\delta)\mu^2\}^{3/2}} \quad \text{and} \quad \beta_2 = \frac{3+\delta(1-\delta)\mu^2\{6+(3\delta^2-3\delta+1)\mu^2\}}{\{1+\delta(1-\delta)\mu^2\}^2}$$

The fact that  $\beta_1$  vanishes at  $\delta = 1/2$  explains the biases of  $S_n$ , which is based on the sample skewness, that one can observe in tables 6.3–6.5. This has also an influence on the Jarque-Bera statistics, especially when n = 50, 100. Under model  $\mathcal{A}_2$ , one has  $E(X^j) = (1 - \delta + \delta\sigma^j)E(Z^j)$ , where  $Z \sim \mathcal{N}(0, 1)$ . As a consequence,  $E(X) = E(X^3) = 0$ ,  $E(X^2) = 1 - \delta + \delta\sigma^2$  and  $E(X^4) = 3(1 - \delta + \delta\sigma^4)$ . Then, in that case,  $var(X) = 1 - \delta + \delta\sigma^2$ ,  $\beta_1 = 0$  and

$$\beta_2 = \frac{3 + 3\delta(\sigma^4 - 1)}{\{1 + \delta(\sigma^2 - 1)\}^2} \,.$$

The weak power of  $S_n$  is then explained by the fact that these alternatives have a null coefficient of skewness.

Table 6.3: Estimation, based on 10 000 replicates, of the power of  $S_n$ ,  $K_n$ ,  $JB_n$ ,  $R_n$ ,  $CVM_n$ ,  $AD_n$  and  $KS_n$  under alternatives of the form  $\ell_{\delta}(z) = (1 - \delta)\phi(z) + \delta h(z)$ ; n = 50

	$\delta = .1$			$\delta = .3$			$\delta = .5$		
Statistics	$\mu = 1$	$\mu = 2$	$\mu = 3$	$\mu = 1$	$\mu = 2$	$\mu = 3$	$\mu = 1$	$\mu = 2$	$\mu = 3$
Sn	5.9	17.2	58.6	4.8	8.4	20.2	4.3	1.4	0.7
Kn	5.3	9.1	26.2	4.7	5.2	13.8	4.6	9.9	50.7
$JB_n$	5.8	15.3	52.9	4.3	5.5	15.3	3.8	1.0	2.4
$R_n$	5.5	10.0	30.1	4.5	3.2	7.3	4.0	4.0	36.6
$\mathrm{CVM}_n$	5.1	11.5	43.8	4.7	12.1	56.3	4.2	6.3	42.2
$AD_n$	5.3	12.8	49.1	4.8	12.2	57.5	4.2	6.8	43.3
$KS_n$	5.3	10.3	36.5	5.0	11.0	46.5	4.5	6.4	31.4
	$\sigma = 1.5$	$\sigma = 2$	$\sigma = 2.5$	$\sigma = 1.5$	$\sigma = 2$	$\sigma = 2.5$	$\sigma = 1.5$	$\sigma = 2$	$\sigma = 2.5$
Sn	8.9	21.4	35.7	11.4	24.2	36.6	10.5	17.5	23.7
Kn	9.7	24.8	45.4	12.7	32.8	56.8	10.6	23.5	37.0
$JB_n$	10.3	26.6	46.8	13.9	34.7	57.1	12.2	25.0	37.9
$\mathbb{R}_n$	8.8	21.5	40.2	12.3	34.8	61.8	12.0	31.0	54.2
$\mathrm{CVM}_n$	5.9	12.0	24.4	7.1	19.5	41.7	7.0	16.8	35.0
$AD_n$	6.3	14.5	29.9	7.8	22.9	47.1	7.8	18.4	37.5
$KS_n$	5.6	9.7	19.2	6.6	15.2	32.0	6.6	13.9	26.9
	$\nu = 5$	$\nu = 10$	$\nu = 15$	$\nu = 5$	$\nu = 10$	$\nu = 15$	$\nu = 5$	$\nu = 10$	$\nu = 15$
Sn	8.3	5.9	5.5	13.8	7.8	6.4	20.6	9.9	7.7
$K_n$	8.2	5.8	5.2	13.5	7.4	6.2	18.7	8.8	6.9
$JB_n$	8.5	5.7	5.3	15.0	8.3	6.5	21.4	10.4	7.6
$R_n$	7.0	5.9	5.4	12.0	7.1	6.1	16.1	8.5	6.4
$\operatorname{CVM}_n$	5.7	5.2	4.7	8.2	5.4	4.9	11.2	6.2	5.1
$AD_n$	6.1	5.3	4.8	9.4	5.8	5.0	13.1	7.1	5.4
$KS_n$	5.6	5.3	4.8	7.3	5.6	5.2	10.2	6.2	5.1

Table 6.4: Estimation, based on 10 000 replicates, of the power of  $S_n$ ,  $K_n$ ,  $JB_n$ ,  $R_n$ ,  $CVM_n$ ,  $AD_n$  and  $KS_n$  under alternatives of the form  $\ell_{\delta}(z) = (1 - \delta)\phi(z) + \delta h(z)$ ; n = 100

		$\delta = .1$			$\delta = .3$			$\delta = .5$	
Statistics	$\mu = 1$	$\mu = 2$	$\mu = 3$	$\mu = 1$	$\mu = 2$	$\mu = 3$	$\mu = 1$	$\mu = 2$	$\mu = 3$
$S_n$	6.9	32.9	89.1	5.9	17.3	51.4	4.6	1.5	0.6
$K_n$	8.3	15.2	49.2	7.2	10.7	31.8	7.1	27.8	90.9
$JB_n$	7.7	30.5	87.3	6.0	14.6	70.7	4.5	4.9	5.6
$\mathbb{R}_n$	5.7	12.6	47.8	4.6	4.2	18.0	3.9	12.7	85.4
$\mathrm{CVM}_n$	4.8	18.4	74.0	5.1	22.7	90.7	4.4	12.2	80.0
$AD_n$	5.1	21.5	80.5	5.4	24.2	91.4	4.7	13.1	81.3
$KS_n$	5.7	16.6	65.1	5.7	20.5	82.6	5.1	10.9	64.9
	$\sigma = 1.5$	$\sigma = 2$	$\sigma = 2.5$	$\sigma = 1.5$	$\sigma = 2$	$\sigma = 2.5$	$\sigma = 1.5$	$\sigma = 2$	$\sigma = 2.5$
$S_n$	11.3	28.8	46.3	14.1	30.4	41.5	13.0	21.9	27.2
$K_n$	16.4	43.8	71.1	21.3	59.9	86.5	19.3	46.0	68.3
$JB_n$	15.9	44.0	70.7	21.6	58.5	84.4	19.7	44.3	64.1
$\mathbb{R}_n$	10.2	30.7	57.6	15.5	54.1	85.6	16.2	48.5	80.6
$\mathrm{CVM}_n$	5.8	15.6	36.7	8.1	31.8	68.7	8.4	28.1	61.6
$AD_n$	6.7	19.9	45.0	9.4	38.0	74.7	9.7	32.3	65.2
$KS_n$	6.3	12.5	28.8	7.8	24.1	56.1	8.1	22.6	49.2
	$\nu = 5$	$\nu = 10$	$\nu = 15$	$\nu = 5$	$\nu = 10$	$\nu = 15$	$\nu = 5$	$\nu = 10$	$\nu = 15$
Sn	11.7	7.1	6.9	22.0	10.1	7.9	32.6	13.7	9.4
$K_n$	13.5	9.1	8.2	23.4	11.7	9.5	31.7	14.6	10.9
$JB_n$	13.3	8.2	7.5	24.9	11.6	8.8	35.5	15.5	10.6
$\mathbb{R}_n$	8.7	5.7	5.4	16.0	7.7	6.1	22.1	8.9	6.9
$\mathrm{CVM}_n$	6.6	4.5	4.8	11.0	5.7	5.1	16.6	6.4	5.3
$AD_n$	7.3	4.8	5.2	13.1	6.3	5.4	19.2	7.4	5.7
$KS_n$	6.8	5.4	5.4	10.3	5.9	6.1	15.2	6.9	6.0

Table 6.5: Estimation, based on 10 000 replicates, of the power of  $S_n$ ,  $K_n$ ,  $JB_n$ ,  $R_n$ ,  $CVM_n$ ,  $AD_n$  and  $KS_n$  under alternatives of the form  $\ell_{\delta}(z) = (1 - \delta)\phi(z) + \delta h(z)$ ; n = 250

	$\delta = .1$			$\delta = .3$			$\delta = .5$		
Statistics	$\mu = 1$	$\mu = 2$	$\mu = 3$	$\mu = 1$	$\mu = 2$	$\mu = 3$	$\mu = 1$	$\mu = 2$	$\mu = 3$
Sn	7.6	63.1	99.7	6.0	39.5	93.2	3.8	1.2	0.3
$K_n$	5.9	21.8	79.8	4.2	10.7	50.3	4.3	45.2	99.7
$JB_n$	7.2	56.2	99.7	4.6	36.9	99.3	3.4	18.6	98.3
$\mathbf{R}_n$	5.7	20.4	83.1	4.4	10.1	49.0	4.3	44.7	100.0
$CVM_n$	6.2	42.8	99.1	6.0	55.7	100.0	5.2	31.7	99.9
$AD_n$	6.4	48.7	99.5	6.3	58.3	100.0	5.2	34.4	99.9
$\mathrm{KS}_n$	6.0	34.5	96.6	5.8	44.3	99.8	5.3	22.3	98.4
	$\sigma = 1.5$	$\sigma = 2$	$\sigma = 2.5$	$\sigma = 1.5$	$\sigma = 2$	$\sigma = 2.5$	$\sigma = 1.5$	$\sigma = 2$	$\sigma = 2.5$
Sn	12.6	32.9	52.9	14.6	31.5	42.8	12.0	21.0	27.4
$K_n$	21.7	70.1	94.7	32.5	88.8	99.5	28.2	75.1	95.4
$JB_n$	22.2	68.9	94.0	31.1	86.4	99.2	26.6	70.4	92.6
$\mathbb{R}_n$	13.5	51.8	86.6	25.0	85.1	99.4	25.7	82.1	99.1
$\mathrm{CVM}_n$	7.7	27.6	67.4	12.4	63.4	97.4	12.8	61.6	95.7
$AD_n$	8.5	35.4	76.7	14.7	71.9	98.4	15.2	66.5	96.8
$\mathrm{KS}_n$	6.5	18.7	51.9	9.3	46.6	91.6	10.0	45.6	88.3
	$\nu = 5$	$\nu = 10$	$\nu = 15$	$\nu = 5$	$\nu = 10$	$\nu = 15$	$\nu = 5$	$\nu = 10$	$\nu = 15$
Sn	13.8	7.1	5.7	34.8	12.9	9.0	54.0	19.4	12.2
$K_n$	16.3	7.8	6.2	36.3	14.3	9.1	52.3	19.4	11.9
$JB_n$	17.1	8.3	6.2	39.9	15.6	10.3	59.0	23.2	14.2
$\mathbf{R}_n$	10.5	6.2	5.5	24.4	9.5	6.5	37.2	12.4	8.3
$CVM_n$	6.9	5.7	5.0	16.3	6.8	5.6	29.3	8.9	6.3
$AD_n$	7.5	5.7	4.8	18.5	7.4	5.9	33.3	10.3	7.0
$KS_n$	6.5	5.4	4.9	13.3	6.2	5.4	23.3	7.5	6.1

## CONCLUSION

Dans ce mémoire, on s'est intéressé à une panoplie de tests de normalité. Plus particulièrement, on a cherché à calculer la puissance de plusieurs des tests les plus populaires. Deux situations ont été considérées, à savoir les puissances à tailles finies et les puissances asymptotiques.

La première contribution de ce travail se situe au chapitre 5. On y retrouve les résultats d'une vaste étude de simulation pour évaluer la puissance de sept tests de normalité. L'originalité tient aux types d'alternatives qui ont été considérées, à savoir des contre-hypothèses locales. Celles-ci permettent d'évaluer la l'efficacité des procédures à rejeter l'hypothèse de normalité sous de faibles écarts à cette loi.

La deuxième contribution fait l'objet du chapitre 6, où le cas asymptotique est considéré. Plus précisément, le comportement asymptotique des statistiques étudiées au chapitre 5 est obtenu sous plusieurs classes d'alternatives dites locales. Ceci permet de calculer des courbes de puissance locales, et ainsi de comparer théoriquement les procédures de test.

Les conclusions des chapitres 5 et 6 concordent remarquablement bien. Autrement dit, les puissances asymptotiques, donc théoriques, sont pratiquement identiques à celles obtenues dans le cas à tailles finies. Ainsi, les calculs

#### CONCLUSION

d'efficacité asymptotique effectuées au chapitre 6 peuvent guider un praticien dans le choix d'un test de normalité approprié. À ce titre, au vu des contrehypothèses utilisées dans ce mémoire, c'est la statistique de Jarque-Bera qui montre, en général, les meilleures puissances.

Une voie possible de recherches futures serait de considérer une version pondérée de la statistique de Jarque-Bera, à savoir

$$JB_n^{\omega} = 2\omega S_n^2 + 2(1-\omega)K_n^2,$$

où  $\omega \in [0,1]$ . Cette statistique est une généralisation de la statistique de Jarque-Bera puisque  $JB_n = JB_n^{1/2}$ . Elle permettrait de donner plus ou moins d'importance aux facteurs d'asymétrie et d'aplatissement. Ainsi, le paramètre  $\omega$  pourrait être ajusté par un utilisateur selon le type d'écart à la normalité qui est attendu, ou souhaitable à détecter.

## ANNEXE A

## PROGRAMMES EN MATLAB

## A.1 Calcul des statistiques de test

### A.1.1 Statistique $S_n$

```
i function S = Sn(X)
2
a = size(X); n = a(1);
-4
5 % Standardisation des observations
6 Xbar = mean(X); Sn = std(X);
7 Z = (X-Xbar)/Sn;
8
9 % Calcul du coefficient d'asymétrie empirique
10 Betal = 0;
for i=l:n
       Beta1 = Beta1 + Z(i)^{3};
12
13 end
14 Betal = Betal/n;
15
16 % Calcul de la statistique de test
17 S = sqrt(n)*abs(Betal)/sqrt(6);
18
19 clear Z;
```

### A.1.2 Statistique $K_n$

```
1 function K = Kn(X)
2
a = size(X); n = a(I);
4
5 % Standardisation des observations
6 Xbar = mean(X); Sn = std(X);
\tau Z = (X-Xbar)/Sn;
8
9 % Calcul du coefficient d'aplatissement empirique
10 Beta2 = 0;
for i = l:n
       Beta2 = Beta2 + Z(i)^4;
12
13 end
14 Beta2 = Beta2/n;
15
16 % Calcul de la statistique de test
17 K = sqrt(n) * abs(Beta2 - 3)/sqrt(24);
18
19 clear Z;
```

### A.1.3 Statistique $JB_n$

```
1 function JB = JBn(X)
2
a = size(X); n = a(1);
4
5 % Standardisation des observations
6 Xbar = mean(X); Sn = std(X);
7 \quad Z = (X - X bar) / Sn;
8
9 % Calcul des coefficients d'asymétrie
10 % et d'aplatissement empiriques
11 Beta 1 = 0; Beta 2 = 0;
12 for i=l:n
        Beta1 = Beta1 + Z(i)^{3};
13
        Beta2 = Beta2 + Z(i)^{4};
1.4
15 end
16 Betal = Betal/n; Beta2 = Beta2/n;
17
18 % Calcul de la statistique de test
IP JB = n * Beta 1^{2/6} + n * (Beta 2 - 3)^{2/24};
20
21 clear Z;
```

Annexe A. Programmes en Matlab

## A.1.4 Statistique $R_n$

```
1 function R = Rn(X)
2
a = size(X); n = a(1);
4
5 % calcul de l'écart-type empirique
6 Sn = std(X);
7
8 % Calcul de l'erreur absolue moyenne (EAM)
9 Xbar = mean(X);
10 EAM = 0;
11 for i=1:n
       EAM = EAM + abs(X(i)-Xbar);
12
13 end
14 EAM = sqrt(pi/2)*Jn/n;
15
16 % calcul de la statistique de test
17 R = sqrt(n) * abs((Sn/EAM) - 1);
```

### A.1.5 Statistique $CVM_n$

```
1 function CVM = CVMn(X)
2
a = size(X); n = a(1);
4
5
   % Standardisation des observations
   Xbar = mean(X); Sn = std(X);
6
   Z = (X-Xbar)/Sn;
7
 8
9 % Calcul des pseudo-observations
10 T = normcdf(Z);
11
12 % Calcul de la statistique de test
13 \text{ sum} 1 = 0; \text{ sum} 2 = 0;
14 for i=1:n
        suml = suml + T(i)^2;
15
        for j=l:n
16
17
            sum2 = sum2 + max(T(i),T(j));
18
        end
19 end
20 \text{ CVM} = (n/3) + \text{sum} I - (\text{sum} 2/n);
21
22 clear Z T;
```

### A.1.6 Statistique $AD_n$

```
function AD = ADn(X)
1
2
  a = size(X); n = a(I);
3
4
   % Standardisation des observations
5
   Xbar = mean(X); Sn = std(X);
6
   Z = (X - X bar) / Sn;
7
8
   % Calcul des pseudo-observations
9
   T = normcdf(Z);
10
11
   % Calcul de la statistique de test
12
   SUMI = 0; SUM2 = 0;
13
14 for i = l:n
       SUM1 = SUM1 + log(1-T(i));
15
        for j = 1:n
16
           temp = max(T(i),T(j));
17
            SUM2 = SUM2 + log((1/temp) - 1);
18
        end
19
20
   end
   AD = (SUM2/n) - 2 * SUM1 - n;
21
22
23 clear Z T;
```

### A.1.7 Statistique $KS_n$

```
1 function KS = KSn(X)
2
a = size(X); n = a(1);
-4
5 % Standardisation des observations
6 Xbar = mean(X); Sn = std(X);
\tau Z = (X-Xbar)/Sn;
8
9 % Calcul des pseudo-observations
10 T = normcdf(Z);
11
12 % Calcul de la statistique de test
13 T = sort(T); Ll = zeros(n, 1);
14 for i=l:n
       L1(i) = max(abs(T(i)-(i/n)), abs(T(i)-((i-1)/n)));
15
16 end
17 KS = sqrt(n) * max(L1);
18
19 clear Z T Ll
```

## A.2 Programmes de simulation selon des alternatives locales

### A.2.1 Mélanges de lois normales

```
1 function X = sim_mixture_norm(n, delta, mu, sigma)
2
3 % Création de l'espace mémoire pour les données
4 X = zeros(n, 1);
 5
6 % Algorithme de simulation
   for i = l: n
 7
       U = rand();
 8
        if (U < delta)
 9
           X(i) = normrnd(mu, sigma, 1, 1);
10
        elseif (U >= delta)
11
12
        X(i) = normrnd(0, 1, 1, 1);
        end
13
14
        clear U;
15
16 end
```

ANNEXE A. PROGRAMMES EN MATLAB

### A.2.2 Mélanges de lois normale et Student

```
function X = sim_mixture_student(n, delta, nu)
L
2
  % Création de l'espace mémoire pour les données
3
4 X = zeros(n, 1);
5
6 % Algorithme de simulation
   for i=l:n
7
       U = rand();
8
       if (U < 1/2)
9
            Y = normrnd(0,1,1,1);
10
           X(i) = -abs(Y);
11
        elseif (U \ge 1/2)
12
            V = rand();
13
            if (V < I - delta)
14
                Y = normrnd(0, 1, 1, 1);
15
                X(i) = abs(Y);
16
            elseif ( V \ge 1 - delta )
17
                Y = trnd(nu,1,1);
18
19
                X(i) = abs(Y);
20
            end
        end
21
   end
22
23
24 clear Y U V;
```

## A.2.3 Alternative asymétrique

```
1 function X = sim_skew(n, delta)
2
   % Création de l'espace mémoire pour les données
3
4 X = zeros(n, 1);
5
6 % Algorithme de simulation (méthode du rejet)
7 for i=1:n
       U=1; temp=0;
8
       while (U > temp)
9
          Y = normrnd(0,1);
temp = normcdf(delta*Y);
10
11
           U = rand();
12
       end
13
       X(i) = Y;
14
15 end
```

ANNEXE A. PROGRAMMES EN MATLAB

### A.3 Estimation des valeurs critiques

```
1 function [qCVM1, qCVM2, qKS1, qKS2, qJB, qR] = quantiles(n, lT)
2
3 CVMI = zeros(IT,1); CVM2 = zeros(IT,1); KS1 = zeros(IT,1);
4 KS2 = zeros(IT, 1); JB = zeros(IT, 1); R = zeros(IT, 1);
5
6 for i=1:IT
       X = normrnd(0, 1, n, 1);
\overline{4}
       [CVM1(i),CVM2(i),KS1(i),KS2(i),JB(i),R(i)] = tests_normality(X);
8
       clear X;
0
10 end
11
12 CVM1 = sort(CVM1);
13 CVM2 = sort(CVM2);
14 KS1 = sort(KS1);
KS2 = sort(KS2);
_{16} JB = sort(JB);
R = sort(R);
18
19 q = ceil(0.95 * IT);
20
qCVMI = CVMI(q);
_{22} qCVM2 = CVM2(q);
_{23} qKS1 = KS1(q);
_{24} qKS2 = KS2(q);
_{25} qJB = JB(q);
qR = R(q);
27
28 clear CVMI; clear CVM2; clear KSI;
29 clear KS2; clear JB; clear R;
```

### A.4 Calculs de puissance

### A.4.1 Puissance à tailles finies sous des mélanges de normales

```
function [pS,pK,pJB,pR,pCVM,pAD,pKS] = power(n,IT)
1
\overline{2}
   delta = [.1, .3, .5];
3
   mu = [1, 2, 3]; sigma = 1;
4
5
   %VC = (1.818, 1.531, 4.516, .531, .128, .753, .883); VC = (1.926, 1.818, 5.568, .522, .126, .750,
6
   .898):
   pS = zeros(3,3);
7
   pK = zeros(3,3);
8
   pJB = zeros(3,3);
9
pR = zeros(3,3);
11 pCVM = zeros(3,3);
pAD = zeros(3,3);
   pKS = zeros(3,3);
13
14
   for i = 1:3
15
        for j = 1:3
16
            for k = I : IT
17
18
                 X = sim_mixture_norm(n, delta(i), mu(j), sigma);
                 if (Sn(X) > VC(1))
19
                     pS(i,j) = pS(i,j) + 1/IT;
20
21
                 end
22
                 if (Kn(X) > VC(2))
23
                     pK(i,j) = pK(i,j) + 1/IT;
                 end
24
                 if (JBn(X) > VC(3))
25
                     pJB(i, j) = pJB(i, j) + 1/1T;
26
27
                 end
                 if (Rn(X) > VC(4))
28
29
                     pR(i,j) = pR(i,j) + 1/IT;
                 end
30
                 if ( CVMn(X) > VC(5) )
31
                     pCVM(i,j) = pCVM(i,j) + 1/IT;
32
                 end
33
34
                 if (ADn(X) > VC(6))
                     pAD(i, j) = pAD(i, j) + 1/IT;
35
                 end
36
                 if (KSn(X) > VC(7))
37
                     pKS(i,j) = pKS(i,j) + 1/IT;
38
                 end
39
40
            end
        \operatorname{end}
41
42
   end
```

## A.4.2 Puissance à tailles finies sous des mélanges de normale et Student

```
function [pS,pK,pJB,pR,pCVM,pAD,pKS] = power(n,IT)
1
2
   delta = [.1, .3, .5];
3
4 nu = [5, 10, 15];
5
   %VC = (1.818, 1.531, 4.516, .531, .128, .753, .883); VC = (1.926, 1.818, 5.568, .522, .126, .750,
6
   .898);
7
   pS = zeros(3,3);
   pK = zeros(3,3);
8
   pJB = zeros(3,3);
.9
10 pR = zeros(3,3);
pCVM = zeros(3,3);
12 pAD = zeros(3,3);
_{13} pKS = zeros(3,3);
14
   for i = 1:3
15
       for j = 1:3
16
            for k=1:IT
17
                X = sim_mixture_student(n, delta(i), nu(j));
18
                if (Sn(X) > VC(1))
19
                    pS(i,j) = pS(i,j) + 1/IT;
20
                end
21
                if (Kn(X) > VC(2))
22
                    pK(i,j) = pK(i,j) + 1/IT;
23
24
                end
                if (JBn(X) > VC(3))
25
                    pJB(i,j) = pJB(i,j) + 1/IT;
26
27
                end
                if (Rn(X) > VC(4))
28
29
                    pR(i,j) = pR(i,j) + 1/IT;
                end
30
                if (CVMn(X) > VC(5))
31
                    pCVM(i, j) = pCVM(i, j) + 1/IT;
32
                end
33
                if (ADn(X) > VC(6))
34
                    pAD(i, j) = pAD(i, j) + 1/IT;
35
36
                end
                if (KSn(X) > VC(7))
37
                    pKS(i,j) = pKS(i,j) + 1/IT;
38
39
                end
            end
40
41
       end
42 end
```

#### A.4.3 Puissance à tailles finies sous l'alternative asymétrique

```
function [pS,pK,pJB,pR,pCVM,pAD,pKS] = power(n,IT)
1
2
   delta = [1, 2, 3];
3
4
   %VC = (1.818, 1,531, 4,516, ,531, .128, .753, .883); VC = (1.926, 1.818, 5.568, .522, .126, .750,
5
   .898);
   pS = zeros(3, 1);
6
   pK = zeros(3,1);
7
   pJB = zeros(3, 1);
8
pR = zeros(3, 1);
10 pCVM= zeros(3,1);
pAD = zeros(3, 1);
pKS = zeros(3, 1);
13
14 for i=1:3
       for k=1:IT
15
16
           X = sim_{skew}(n, delta(i));
            if (Sn(X) > VC(1))
17
                pS(i,j) = pS(i,j) + 1/IT;
18
19
            end
           if (Kn(X) > VC(2))
20
                pK(i,j) = pK(i,j) + I/IT;
21
           end
22
            if (JBn(X) > VC(3))
23
                pJB(i,j) = pJB(i,j) + l/IT;
24
           end
25
           if (Rn(X) > VC(4))
26
                pR(i,j) = pR(i,j) + 1/IT;
27
           end
28
29
           if (CVMn(X) > VC(5))
                pCVM(i,j) = pCVM(i,j) + 1/1T;
30
           end
31
           if (ADn(X) > VC(6))
32
                pAD(i,j) = pAD(i,j) + 1/IT;
33
           end
34
           if (KSn(X) > VC(7))
35
                pKS(i,j) = pKS(i,j) + 1/IT;
36
           end
37
       end
38
39 end
```

#### A.4.4 Courbes de puissance locale

```
function [beta_CVM, beta_AD, beta_KS] = LP_curve(model, a, N, M, IT, delta)
11
2
3 beta_CVM = 0;
4 beta_AD=0;
5 beta_KS=0;
6
   for i=I:IT
7
       X = normrnd(0, 1, N, 1);
8
       Z = (X - mean(X)) / std(X);
9
       T = normcdf(Z);
10
11
       Fo=zeros(M,1);
12
13
        for m=1:M
            ml = m - .5;
14
            F = sum(T \le (mI/M));
15
            Fo(m) = (F/sqrt(N)) - sqrt(N)*mI/M;
16
       end
17
18
19
       Q1 = zeros(M, 1); Q2 = zeros(M, 1);
20
        for m=1:M
            m! = m - .5;
21
            temp = Fo(m) + delta * xi(model, (m-.5)/M, a);
22
            Ql(m) = temp;
23
            Q2(m) = temp / sqrt(ml*(M-ml));
24
25
       end
26
       CVM hat = Q1. '*Q1/M;
27
       AD_hat = M*Q2.'*Q2;
28
        KS_hat = max(abs(Q1));
29
30
        clear QI Q2 Fo X Z T;
31
32
        if CVM hat > 0.126
33
            beta_CVM = beta_CVM + I/IT;
34
35
       end
        if AD_{hat} > 0.751
36
            beta_AD = beta_AD + 1/IT;
37
       end
38
        if KS_hat > 0.898
20
            beta_KS = beta_KS + 1/IT;
40
41
       end
42 end
```
## Références

- AZZALINI, A. (1985). A class of distributions which includes the normal ones. Scand. J. Statist. 12, 171–178.
- BERG, D. & QUESSY, J.-F. (2009). Local power analyses of goodness-of-fit tests for copulas. *Scand. J. Statist.*.
- BOWMAN, K. O. & SHENTON, L. R. (1975). Omnibus test contours for departures from normality based on  $\sqrt{b_1}$  and  $b_2$ . Biometrika 62, 243–250.
- CASELLA, G. & BERGER, R. L. (1990). Statistical inference. The Wadsworth & Brooks/Cole Statistics/Probability Series. Pacific Grove, CA: Wadsworth & Brooks/Cole Advanced Books & Software.
- CRAMÉR, H. (1928). On the composition of elementary errors. Skand. Aktuarietidskr 11, 13–74.
- D'AGOSTINO, R. & PEARSON, E. S. (1973). Tests for departure from normality. Empirical results for the distributions of  $b_2$  and  $\sqrt{b_1}$ . Biometrika **60**, 613–622.

- D'AGOSTINO, R. & STEPHENS, M. (1986). Goodness-of-fit techniques. CRC.
- DURBIN, J. (1973). Weak convergence of the sample distribution function when parameters are estimated. Ann. Statist. 1, 279–290.
- DURBIN, J. & KNOTT, M. (1972). Components of Cramér-von Mises statistics. I. J. Roy. Statist. Soc. Ser. B 34, 290–307.
- DURBIN, J., KNOTT, M. & TAYLOR, C. C. (1975). Components of Cramérvon Mises statistics. II. J. Roy. Statist. Soc. Ser. B 37, 216–237.
- DURIO, A. & NIKITIN, Y. Y. (2003). Local Bahadur efficiency of some goodness-of-fit tests under skew alternatives. J. Statist. Plann. Inference 115, 171–179.
- GEARY, R. C. (1947). Testing for normality. Biometrika 34, 209-242.
- GEL, Y. R. & GASTWIRTH, J. L. (2008). A robust modification of the Jarque-Bera test of normality. *Econom. Lett.* **99**, 30–32.
- GEL, Y. R., MIAO, W. & GASTWIRTH, J. L. (2007). Robust directed tests of normality against heavy-tailed alternatives. *Comput. Statist. Data Anal.* 51, 2734–2746.
- GHOUDI, K. & RÉMILLARD, B. (1998). Empirical processes based on pseudo-observations. In Asymptotic methods in probability and statistics (Ottawa, ON, 1997). Amsterdam: North-Holland, pp. 171–197.

- JARQUE, C. M. & BERA, A. K. (1980). Efficient tests for normality, homoscedasticity and serial independence of regression residuals. *Econom. Lett.* 6, 255–259.
- JARQUE, C. M. & BERA, A. K. (1987). A test for normality of observations and regression residuals. *Internat. Statist. Rev.* 55, 163–172.
- JOGESH BABU, G. & RAO, C. R. (2004). Goodness-of-fit tests when parameters are estimated. Sankhyā 66, 63-74.
- KOLMOGOROV, A. (1933). On the empirical determination of a distribution. Breakthroughs in statistics 2, 106–113.
- KOZIOL, J. A. (1986). Relative efficiencies of goodness of fit procedures for assessing univariate normality. Ann. Inst. Statist. Math. 38, 485–493.
- PEARSON, E. S., D'AGOSTINO, R. B. & BOWMAN, K. O. (1977). Tests for departure from normality: Comparison of powers. *Biometrika* 64, 231– 246.
- ROTHE, G. (1981). Some properties of the asymptotic relative Pitman efficiency. Ann. Statist. 9, 663–669.
- SHAPIRO, S. S., WILK, M. B. & CHEN, H. J. M. (1968). A comparative study of various tests for normality. J. Amer. Statist. Assoc 63, 1343–1372.
- SMIRNOV, E. & POLEJAEFF, W. (1934). Density of Population and Sterility of the Females in the Coccid Lepidosaphes ulmi L. The Journal of Animal Ecology, 29–40.

- STEPHENS, M. A. (1974). Edf statistics for goodness of fit and some comparisons. Journal of the American Statistical Association 69, 730-737.
- STEPHENS, M. A. (1976). Asymptotic results for goodness-of-fit statistics with unknown parameters. Ann. Statist. 4, 357–369.
- THADEWALD, T. & BÜNING, H. (2007). Jarque-Bera test and its competitors for testing normality—a power comparison. J. Appl. Stat. 34, 87–105.
- THODE JR., H. (2002). Testing for Normality, number 164 in 'Statistics: Textbooks and Monographs'.
- VAN DER VAART, A. W. & WELLNER, J. A. (1996). Weak convergence and empirical processes. Springer Series in Statistics. New York: Springer-Verlag. With applications to statistics.
- VASICEK, O. (1976). A test for normality based on sample entropy. J. Roy. Statist. Soc. Ser. B 38, 54–59.
- VON MISES, R. (1931). Wahrscheinlichkeitsrechnung 316-335. Deuticke, Leipzig.
- WIEAND, H. S. (1976). A condition under which the Pitman and Bahadur approaches to efficiency coincide. Ann. Statist. 4, 1003–1011.