

38 *2.º semestre*

UNIVERSIDAD NACIONAL AUTONOMA DE MEXICO
FACULTAD DE CIENCIAS



UNA MODIFICACION A LA ESTADISTICA
DE SHAPIRO - WILK

T E S I S
PARA OBTENER EL TITULO DE
LICENCIADO EN ACTUARIA
P R E S E N T A

PEDRO MIGUEL QUIBRERA MATIENZO

MEXICO, D. F.

ABRIL DE 1981



Universidad Nacional
Autónoma de México



UNAM – Dirección General de Bibliotecas
Tesis Digitales
Restricciones de uso

DERECHOS RESERVADOS ©
PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

INDICE

INTRODUCCIÓN.....	1
I.. LA PRUEBA DE SHAPIRO Y WILK.	
a) Estimadores de Lloyd.....	3
b) La estadística de prueba.....	10
II.. MODIFICACIÓN PROPUESTA.	
a) Derivación del estimador $\hat{\sigma}_U^{(n)}$	17
b) Propiedades analíticas y asintóticas del estimador $\hat{\sigma}_U^{(n)}$	32
c) Estructura y características de la estadística Propuesta.....	35
III.. SIMULACIONES DE LA DISTRIBUCIÓN UOLA DE $W_U^{(n)}$ Y DE SU POTENCIA.	
a) Una aproximación a la distribución nula de $W_U^{(n)}$	41
b) Potencia empírica de $W_U^{(n)}$	44
c) Conclusiones.....	48
APÉNDICE A.....	49
APÉNDICE B.....	60
APÉNDICE C.....	64
APÉNDICE D.....	67
REFERENCIAS.....	80

INTRODUCCIÓN.

1

El presente trabajo, es un breve estudio de las propiedades de potencia que presenta una modificación a la estadística de Shapiro y Wilk, usada en la prueba para decidir si una población tiene una distribución que se ajusta a la distribución normal. La investigación se realizó simulando tanto la distribución de la nueva estadística, como su potencia, puesto que a la fecha se desconoce su distribución teórica.

Las motivaciones que llevaron al estudio de esta modificación, son las siguientes ventajas que presenta sobre la estadística original: 1) Es posible calcularla para cualquier tamaño de muestra, pues no se requieren tablas en el proceso de cálculo. Así mismo, este último se realiza con gran rapidez, debido a la existencia de un método recursivo que facilita las operaciones.

2) Se conoce su distribución asintótica, lo que permite determinar aproximadamente su comportamiento, cuando el tamaño de muestra es suficientemente grande.

El contenido está distribuido como a continuación se indica: El primer capítulo trata de la estructura y propiedades analíticas de la estadística de Shapiro-Wilk. Toda or-

seguida, al turno a la modificación propuesta, discutiéndose con lujo de detalle su derivación teórica y sus propiedades asintóticas. El capítulo tercero describe los procedimientos usados en las simulaciones de su distribución y potencia. Finalmente, a través de un análisis comparativo de la efectividad de ambas estadísticas, se concluye respecto a la utilidad de la nueva estadística.

Nota aclaratoria: Este trabajo parece de apéndice, debido al poco espacio del autor.

I. LA PRUEBA DE SHAPIRO-WILK.

3

S.S. Shapiro y M.B. Wilk, en su artículo: "An analysis of variance test for normality" (1965) derivan un nuevo procedimiento estadístico, para determinar si una muestra aleatoria proviene o no de una distribución normal.

Esencialmente el procedimiento consiste en comparar a través de un cociente, a dos estimadores de la varianza. El numerador es el cuadrado del estimador de Lloyd, muy sensible a fallas en la normalidad; y el denominador es el estimador usual S^2 , robusto ante no normalidad. Al efectuarse el cociente se logra que la nueva estadística sea no paramétrica, es decir, su distribución no depende de los parámetros de localización y escala, haciéndola apropiada para probar la hipótesis de normalidad.

Con el propósito de que el lector se forme una idea clara respecto a esta estadística, se describirán brevemente la derivación y principales propiedades estadísticas de su numerador.

a) ESTIMADORES DE LLOYD.

En 1952, F.H. Lloyd, usando las estadísticas de orden, desarrolló un procedimiento para estimar los parámetros de localización y escala de una familia continua de distribu-

ciones. El propósito de esta sección, es exponer escuetamente tal procedimiento.

4

Denotamos con las letras μ y σ a los parámetros de localización y escala respectivamente, nótese que no necesariamente son la media y varianza de la familia.

Sea X una variable aleatoria cuya distribución pertenece a la familia. Entonces si consideramos la estandarización de dicha variable:

$$Y = \frac{X - \mu}{\sigma}$$

la función de densidad de esta nueva variable, no depende de los parámetros. Por tal motivo, tomando una muestra aleatoria de tamaño n , X_1, \dots, X_n de una distribución perteneciente a la familia, si estandarizamos cada variable y consideramos las n estadísticas de orden correspondientes $Y_{(1)}^{(n)}, Y_{(2)}^{(n)}, \dots, Y_{(n)}^{(n)}$, el vector de medias y la matriz de varianzas y covarianzas, son independientes de μ y σ , es decir:

$$\text{si } \forall_{i \in \{1, \dots, n\}} \mathbb{E}[Y_{(i)}^{(n)}] = m_i^{(n)}$$

$$\text{y } \forall_{i, j \in \{1, \dots, n\}} \text{cov}(Y_{(i)}^{(n)}, Y_{(j)}^{(n)}) = v_{ij}^{(n)}$$

tales cantidades dependen sólo de la función de densidad de Y .


Ahora bien, como:

$$\forall i \in \{1, \dots, n\} \quad Y_{(i)}^{(n)} = \frac{X_{(i)}^{(n)} - \mu}{\sigma}$$

se puede pensar que:

$$\forall i \in \{1, \dots, n\} \quad \mathbb{E}[X_{(i)}^{(n)}] = \mu + \sigma m_i^{(n)}$$

es una recta de regresión:



Podemos estimar a μ y σ , aplicando la teoría de mínimos cuadrados generalizados, obteniendo así, los estimadores insesgados de mínima varianza dentro de la clase de estimadores insesgados lineales en $X_{(1)}^{(n)}, \dots, X_{(n)}^{(n)}$. Para visualizar la situación más claramente, consideremos la notación matricial que comúnmente se maneja en regresión.

$$\text{Tomando } \underline{X}^{(n)} = \begin{pmatrix} X_{(1)}^{(n)} \\ \vdots \\ X_{(n)}^{(n)} \end{pmatrix}$$

$$Y^{(n)} = \begin{pmatrix} Y_{(1)}^{(n)} \\ \vdots \\ Y_{(n)}^{(n)} \end{pmatrix}, \quad \underline{m}^{(n)} = \begin{pmatrix} m_{(1)}^{(n)} \\ \vdots \\ m_{(n)}^{(n)} \end{pmatrix}$$

6

$$y \quad V^{(n)} = (\sigma_{ij}^{(n)}) \quad i, j \in 1, \dots, n$$

Las relaciones anteriores se expresan de la manera siguiente:

$$E [Y^{(n)}] = \underline{m}^{(n)}$$

$$\text{Var} [Y^{(n)}] = V^{(n)}$$

$$y \quad E [\underline{x}^{(n)}] = \mu \underline{1}^{(n)} + \sigma \underline{m}^{(n)}$$

$$= \left(\underline{1}^{(n)}, \underline{m}^{(n)} \right) \begin{pmatrix} \mu \\ \sigma \end{pmatrix}$$

$$y \quad \text{Var} (\underline{x}^{(n)}) = \sigma^2 V^{(n)}$$

La estimación por mínimos cuadrados generalizados del vector $(\mu, \sigma)'$, se obtiene minimizando la forma cuadrática:

$$\left[\underline{x}^{(n)} - \left(\underline{1}^{(n)}, \underline{m}^{(n)} \right) \begin{pmatrix} \mu \\ \sigma \end{pmatrix} \right]' V^{(n)-1} \left[\underline{x}^{(n)} - \left(\underline{1}^{(n)}, \underline{m}^{(n)} \right) \begin{pmatrix} \mu \\ \sigma \end{pmatrix} \right]$$

Al minimizar obtenemos:

$$\begin{pmatrix} \hat{\mu} \\ \hat{\sigma} \end{pmatrix} = \left[\left(\underline{1}^{(n)}, \underline{m}^{(n)} \right)' V^{(n)-1} \left(\underline{1}^{(n)}, \underline{m}^{(n)} \right) \right]^{-1} \left(\underline{1}^{(n)}, \underline{m}^{(n)} \right)' V^{(n)-1} \underline{x}^{(n)}$$

cuya matriz de varianzas y covarianzas es:

$$\begin{aligned} & \left[(\underline{1}^{(n)}, \underline{m}^{(n)})' V_{\hat{\beta}}^{-1} (\underline{1}^{(n)}, \underline{m}^{(n)}) \right]^{-1} (\underline{1}^{(n)}, \underline{m}^{(n)})' V_{\hat{\beta}}^{-1} \sigma^2 V_{\hat{\beta}}^{-1} \underline{x}^{(n)} \\ & \quad V_{\hat{\beta}}^{-1} (\underline{1}^{(n)}, \underline{m}^{(n)}) \left[(\underline{1}^{(n)}, \underline{m}^{(n)})' V_{\hat{\beta}}^{-1} (\underline{1}^{(n)}, \underline{m}^{(n)}) \right]^{-1} \\ & = \sigma^2 \left((\underline{1}^{(n)}, \underline{m}^{(n)})' V_{\hat{\beta}}^{-1} (\underline{1}^{(n)}, \underline{m}^{(n)}) \right)^{-1} \end{aligned}$$

Ahora:

$$\begin{aligned} \left[(\underline{1}^{(n)}, \underline{m}^{(n)})' V_{\hat{\beta}}^{-1} (\underline{1}^{(n)}, \underline{m}^{(n)}) \right]^{-1} & = \begin{pmatrix} \underline{1}^{(n)'} V_{\hat{\beta}}^{-1} \underline{1}^{(n)} & \underline{1}^{(n)'} V_{\hat{\beta}}^{-1} \underline{m}^{(n)} \\ \underline{1}^{(n)'} V_{\hat{\beta}}^{-1} \underline{m}^{(n)} & \underline{m}^{(n)'} V_{\hat{\beta}}^{-1} \underline{m}^{(n)} \end{pmatrix}^{-1} \\ & = \frac{1}{\Delta^{(n)}} \begin{pmatrix} \underline{m}^{(n)'} V_{\hat{\beta}}^{-1} \underline{m}^{(n)} & -\underline{1}^{(n)'} V_{\hat{\beta}}^{-1} \underline{m}^{(n)} \\ -\underline{1}^{(n)'} V_{\hat{\beta}}^{-1} \underline{m}^{(n)} & \underline{1}^{(n)'} V_{\hat{\beta}}^{-1} \underline{1}^{(n)} \end{pmatrix} \end{aligned}$$

donde

$$\Delta^{(n)} = (\underline{1}^{(n)'} V_{\hat{\beta}}^{-1} \underline{1}^{(n)}) (\underline{m}^{(n)'} V_{\hat{\beta}}^{-1} \underline{m}^{(n)}) - (\underline{1}^{(n)'} V_{\hat{\beta}}^{-1} \underline{m}^{(n)})^2$$

Usando esta reducción, las expresiones de $\hat{\mu}$ y $\hat{\sigma}^2$ se reducen a:

$$\begin{aligned} \begin{pmatrix} \hat{\mu} \\ \hat{\sigma}^2 \end{pmatrix} & = \frac{1}{\Delta^{(n)}} \begin{pmatrix} \underline{m}^{(n)'} V_{\hat{\beta}}^{-1} \underline{m}^{(n)} & -\underline{1}^{(n)'} V_{\hat{\beta}}^{-1} \underline{m}^{(n)} \\ -\underline{1}^{(n)'} V_{\hat{\beta}}^{-1} \underline{m}^{(n)} & \underline{1}^{(n)'} V_{\hat{\beta}}^{-1} \underline{1}^{(n)} \end{pmatrix} \begin{pmatrix} \underline{1}^{(n)'} V_{\hat{\beta}}^{-1} \\ \underline{m}^{(n)'} V_{\hat{\beta}}^{-1} \end{pmatrix} \underline{x}^{(n)} \\ & = \frac{1}{\Delta^{(n)}} \begin{pmatrix} \underline{m}^{(n)'} V_{\hat{\beta}}^{-1} \underline{m}^{(n)} \underline{1}^{(n)'} V_{\hat{\beta}}^{-1} - \underline{1}^{(n)'} V_{\hat{\beta}}^{-1} \underline{m}^{(n)} \underline{1}^{(n)'} V_{\hat{\beta}}^{-1} \\ -\underline{1}^{(n)'} V_{\hat{\beta}}^{-1} \underline{m}^{(n)} \underline{1}^{(n)'} V_{\hat{\beta}}^{-1} + \underline{1}^{(n)'} V_{\hat{\beta}}^{-1} \underline{1}^{(n)} \underline{m}^{(n)'} V_{\hat{\beta}}^{-1} \end{pmatrix} \underline{x}^{(n)} \end{aligned}$$

ie

$$\begin{aligned} \hat{\mu} & = \frac{1}{\Delta^{(n)}} \left(-\underline{m}^{(n)'} V_{\hat{\beta}}^{-1} (\underline{1}^{(n)} \underline{m}^{(n)'} - \underline{m}^{(n)'} \underline{1}^{(n)}) V_{\hat{\beta}}^{-1} \underline{x}^{(n)} \right) \\ \hat{\sigma}^2 & = \frac{1}{\Delta^{(n)}} \left(\underline{1}^{(n)'} V_{\hat{\beta}}^{-1} (\underline{1}^{(n)} \underline{m}^{(n)'} - \underline{m}^{(n)'} \underline{1}^{(n)}) V_{\hat{\beta}}^{-1} \underline{x}^{(n)} \right) \end{aligned}$$

De igual forma:

$$\text{Var}(\hat{\mu}) = \frac{\sigma^2}{\Delta} \underline{m}^{(n)'} V(\hat{n}) \underline{m}^{(n)}$$

$$\text{Var}(\hat{\sigma}) = \frac{\sigma^2}{\Delta} \underline{1}^{(n)'} V(\hat{n}) \underline{1}^{(n)}$$

$$\text{cov}(\hat{\mu}, \hat{\sigma}) = -\frac{\sigma^2}{\Delta} \underline{1}^{(n)'} V(\hat{n}) \underline{m}^{(n)}$$

Teniendo en cuenta que para nuestros propósitos las variables X_1, \dots, X_n se distribuyen normalmente bajo la hipótesis nula, podemos aplicar al cálculo de los estimadores de Lloyd, ciertos resultados algebraicos concernientes al vector de medias y a la matriz de varianzas y covarianzas de las estadísticas de orden estandarizadas, con el propósito de obtener una expresión más simple de la estadística de Shapiro-Wilk.

Tales resultados son:

$$(a) \quad \underline{1}^{(n)'} V(\hat{n}) \underline{m}^{(n)} = 0^{(n)}$$

$$(b) \quad V(\hat{n}) \underline{1}^{(n)} = \underline{1}^{(n)}$$

(La demostración se encuentra en el apéndice A). Usando el resultado (a), la expresión denotada por Δ , se simplifica de:

$$\Delta^{(n)} = (\underline{1}^{(n)'} V(\hat{n}) \underline{1}^{(n)}) (\underline{m}^{(n)'} V(\hat{n}) \underline{m}^{(n)}) - (\underline{1}^{(n)'} V(\hat{n}) \underline{m}^{(n)})^2$$

$$a \quad \Delta^{(n)} = (\underline{1}^{(n)'} V(\hat{n}) \underline{1}^{(n)}) (\underline{m}^{(n)'} V(\hat{n}) \underline{m}^{(n)})$$

por lo que $\hat{\mu}$ se reduce de:

9

$$\hat{\mu} = -\frac{1}{\Delta^{(n)}} \underline{m}^{(n)'} V^{(n)} (\underline{1}^{(n)} \underline{m}^{(n)'} - \underline{m}^{(n)'} \underline{1}^{(n)'}) V^{(n)} \underline{x}^{(n)}$$

a

$$\hat{\mu} = \frac{\underline{m}^{(n)'} V^{(n)} \underline{m}^{(n)} \underline{1}^{(n)'} V^{(n)} \underline{x}^{(n)}}{(\underline{1}^{(n)'} V^{(n)} \underline{1}^{(n)}) (\underline{m}^{(n)'} V^{(n)} \underline{m}^{(n)})} = \frac{\underline{1}^{(n)'} V^{(n)} \underline{x}^{(n)}}{\underline{1}^{(n)'} V^{(n)} \underline{1}^{(n)}}$$

usando ahora el resultado (b)

$$V^{(n)} \underline{1}^{(n)} = \underline{1}^{(n)} \text{ i.e. } \underline{1}^{(n)'} V^{(n)} = \underline{1}^{(n)'}$$

$$\hat{\mu} = \frac{\underline{1}^{(n)'} \underline{x}^{(n)}}{\underline{1}^{(n)'} \underline{1}^{(n)}} = \bar{x}^{(n)} = \bar{x} \text{ el promedio de la muestra sin ordenar.}$$

La reducción de $\hat{\sigma}$ es de:

$$\hat{\sigma} = \frac{1}{\Delta^{(n)}} \underline{1}^{(n)'} V^{(n)} (\underline{1}^{(n)} \underline{m}^{(n)'} - \underline{m}^{(n)'} \underline{1}^{(n)'}) V^{(n)} \underline{x}^{(n)} \quad a$$

$$\hat{\sigma} = \frac{\underline{1}^{(n)'} V^{(n)} \underline{1}^{(n)} \underline{m}^{(n)'} V^{(n)} \underline{x}^{(n)}}{\underline{1}^{(n)'} V^{(n)} \underline{1}^{(n)} \underline{m}^{(n)'} V^{(n)} \underline{m}^{(n)}} = \frac{\underline{m}^{(n)'} V^{(n)} \underline{x}^{(n)}}{\underline{m}^{(n)'} V^{(n)} \underline{m}^{(n)}}$$

y en lo concerniente a las varianzas de los estimadores y a su covarianza, se obtienen:

$$\text{Var}(\hat{\mu}) = \frac{\sigma^2}{\underline{1}^{(n)'} V^{(n)} \underline{1}^{(n)}}$$

$$\text{Var}(\hat{\sigma}) = \frac{\sigma^2}{\underline{m}^{(n)'} V^{(n)} \underline{m}^{(n)}} \quad \text{y } \text{cov}(\hat{\mu}, \hat{\sigma}) = 0$$

Como comentario final a esta sección, - cabe notar la fuerte dependencia del estimador de Lloyd $\hat{\sigma}$ de la desviación estándar, de la hipótesis de normalidad, puesto que sus coeficientes se encuentran en función de $\mu^{(n)}$ y $\nu^{(n)}$, valores que a su vez dependen totalmente del tamaño de muestra y de la familia de donde se muestra.

Este mismo hecho, ocasiona el uso inevitable de tablas para el cálculo de la estadística de Shapiro-Wilk, más lo peor del caso, es que tan sólo se conocen $\mu^{(n)}$ para $n \leq 50$ y $\nu^{(n)}$ hasta $n=20$, teniendo que recurrirse a la aproximación para tamaños de muestra mayores. Tal situación junto con el total desconocimiento de propiedades asintóticas, se traducen en grandes limitaciones de la estadística de Shapiro y Wilk.

b) LA ESTADÍSTICA DE PRUEBA.

Como se mencionó al inicio de este capítulo, el procedimiento estadístico de Shapiro y Wilk para la detección de normalidad en una muestra aleatoria, se basa en la comparación de dos estimadores del parámetro de escala de la distribución a través de un cociente: el cuadrado del estimador de Lloyd y el conocido estimador s^2 .

Con el propósito de que la estadística de prueba tenga ciertas propiedades analíticas, los autores modificaron ligeramente al estimador de Lloyd, multiplicándolo por determinadas constantes. Tal modificación es:

$$\hat{\sigma}^* = \frac{\underline{m}^{(n)'} \underline{v}^{(n)'} \underline{m}^{(n)}}{(\underline{m}^{(n)'} \underline{v}^{(n)'} \underline{v}^{(n)'} \underline{m}^{(n)})^{1/2}} \hat{\sigma}$$

Substituyendo el valor de $\hat{\sigma}$:

$$\begin{aligned} \hat{\sigma}^* &= \frac{\underline{m}^{(n)'} \underline{v}^{(n)'} \underline{m}^{(n)}}{(\underline{m}^{(n)'} \underline{v}^{(n)'} \underline{v}^{(n)'} \underline{m}^{(n)})^{1/2}} \cdot \frac{\underline{m}^{(n)'} \underline{v}^{(n)'} \underline{x}^{(n)}}{\underline{m}^{(n)'} \underline{v}^{(n)'} \underline{m}^{(n)}} \\ &= \frac{\underline{m}^{(n)'} \underline{v}^{(n)'} \underline{x}^{(n)}}{(\underline{m}^{(n)'} \underline{v}^{(n)'} \underline{v}^{(n)'} \underline{m}^{(n)})^{1/2}} \end{aligned}$$

Tomando $\underline{a}^{(n)} = \frac{\underline{v}^{(n)'} \underline{m}^{(n)}}{(\underline{m}^{(n)'} \underline{v}^{(n)'} \underline{v}^{(n)'} \underline{m}^{(n)})^{1/2}}$

$$\hat{\sigma}^* = \frac{\underline{a}^{(n)'} \underline{x}^{(n)}}{1} = \underline{a}^{(n)'} \underline{x}^{(n)}$$

La expresión de la estadística de prueba, que de ahora en adelante denotaremos por $W^{(n)}$, es por tanto:

$$\begin{aligned} W^{(n)} &= \frac{(\hat{\sigma}^*)^2}{(n-1)S^2} \\ &= \frac{(\underline{m}^{(n)'} \underline{v}^{(n)'} \underline{x}^{(n)})^2}{(\underline{m}^{(n)'} \underline{v}^{(n)'} \underline{v}^{(n)'} \underline{m}^{(n)}) (n-1)S^2} \end{aligned}$$

$$\begin{aligned}
 \text{ie } W^{(n)} &= \frac{(\underline{a}^{(n)'} \underline{x}^{(n)})^2}{(n-1)S^2} \\
 &= \frac{\left(\sum_{i=1}^n a_i x_{(i)}\right)^2}{\sum_{i=1}^n (x_i - \bar{x})^2}
 \end{aligned}$$

El estimador S^2 siempre es un estimador viesado de la varianza poblacional, sea cual sea la familia de distribuciones de donde provenga la muestra, es decir S^2 es un estimador robusto ante no normalidad. Este hecho, aunado a la gran sensibilidad del estimador de la varianza de Lloyd a fallas de normalidad, provoca un comportamiento peculiar de $W^{(n)}$: cuando la hipótesis nula es cierta, es decir, cuando la muestra proviene efectivamente de una distribución normal, ambos estimadores estiman (salvo por una constante), a la varianza poblacional; mientras que en ausencia de normalidad, aun cuando el denominador sigue estimando a un múltiplo de la varianza, la enorme sensibilidad del numerador, ocasiona grandes distorsiones en la estimación de dicho parámetro. Tal situación ha sido estudiada con lujo de detalle por los autores Shapiro y Wilk, quienes a través de la simulación han encontrado que para ciertas familias de distribución distintas de la normal, los valores medios de $W^{(n)}$, tienden a cargarse a la izquierda de los correspondientes a la familia normal. Así mismo, la varianza ba-

lo normalidad; la varianza simulada de $W^{(n)}$ es 13
 en general más pequeña que la respectiva a las
 poblaciones no normales estudiadas.

Notéese que la modificación al estimador de
 Lloyd $\hat{\sigma}^*$, ya no es sesgado:

$$\begin{aligned} E(\hat{\sigma}^*) &= E(\underline{q}^{(n)' } \underline{x}^{(n)}) \\ &= \frac{\underline{m}^{(n)' } \underline{V}^{(n)-1}}{(\underline{m}^{(n)' } \underline{V}^{(n)-1} \underline{V}^{(n)-1} \underline{m}^{(n)})^{1/2}} E(\underline{\mu} \underline{L}^{(n)} + \sigma \underline{y}^{(n)}) \\ &= \frac{\underline{m}^{(n)' } \underline{V}^{(n)-1}}{(\underline{m}^{(n)' } \underline{V}^{(n)-1} \underline{V}^{(n)-1} \underline{m}^{(n)})^{1/2}} (\underline{\mu} \underline{L}^{(n)} + \sigma \underline{m}^{(n)}) \\ &= \sigma \frac{\underline{m}^{(n)' } \underline{V}^{(n)-1} \underline{m}^{(n)}}{(\underline{m}^{(n)' } \underline{V}^{(n)-1} \underline{V}^{(n)-1} \underline{m}^{(n)})^{1/2}} \end{aligned}$$

Las principales propiedades analíticas de
 $W^{(n)}$ son:

1) No depende de cambios en los parámetros
 de localización y escala.

2) En presencia de normalidad, la distribu-
 ción de $W^{(n)}$, sólo depende del tamaño de
 muestra, no de los parámetros.

3) En presencia de normalidad, $W^{(n)}$ es -
 independiente de S^2 y \bar{X} .

4)

$$\forall r \in \mathbb{N} \quad E(W^{(n)r}) = \frac{E(\hat{\sigma}^{*2r})}{(n-1) E(S^{2r})}$$

$$5) E[W^{(n)}] = \frac{\underline{m}^{(n)'} V^{(n)'} \underline{m}^{(n)} [\underline{m}^{(n)'} V^{(n)'} \underline{m}^{(n)} + 1]}{(n-1) \underline{m}^{(n)'} V^{(n)'} V^{(n)'} \underline{m}^{(n)}}$$

14

6) Los valores máximo y mínimo de $W^{(n)}$ son respectivamente: 1 y $\frac{n d_1^2}{n-1}$ donde $d_1^{(n)}$ es la primera entrada $\underline{q}^{(n)}$.

En lo que concierne a la distribución de $W^{(n)}$, todavía no se ha podido determinar explícitamente para cualesquiera que sea el tamaño de la muestra, debido a la enorme complejidad que involucra el uso de los momentos de primer y segundo orden de las estadísticas de orden correspondientes a una muestra normal estandarizada. Tales circunstancias han conducido al uso de la simulación como único camino para un conocimiento aproximado de los principales percentiles de $W^{(n)}$.

Así pues, muestreando de una distribución normal, los autores calcularon repetidos valores de $W^{(n)}$ y, ajustando los percentiles obtenidos por el sistema de curvas de frecuencia de N.L. Johnson, se obtuvo entonces una aproximación empírica a la distribución nula de $W^{(n)}$.

Tal procedimiento lo efectuaron desde $n=3$ hasta $n=20$, con un tamaño de simulación de 5000 y desde $n=21$ hasta $n=50$ usaron: tamaño de la simulación igual a 100 000 / n .

Recordará el lector que se conoce la matriz de varianzas y covarianzas solo para tamaños de muestra menores o iguales a veinte, por tanto, para valores mayores, los autores han aproximado el valor del vector:

$$\underline{a}^{(n)} = \frac{m^{(n)} V \bar{h}'}{(m^{(n)} V \bar{h}' V \bar{h}' m^{(n)})^{1/2}} \quad \text{por:}$$

$$\hat{a}_i^{(n)} = \frac{2 m_i^{(n)}}{\hat{c}_i^{(n)}} \quad \text{para } i=2, \dots, n-1$$

donde:

$$\hat{c}_i^{(n)} = -2.722 + 4.083n$$

y para $i=1, n$

$$\hat{a}_1^{(n)} = \hat{a}_n^{(n)} = \frac{\Gamma(\gamma_2(n+1))}{(2\Gamma(\gamma_2(n+1)))^{1/2}}$$

Una vez obtenidos los percentiles, la potencia de la prueba se simuló tomando 200 muestras aleatorias de diversas distribuciones, para distintos tamaños de muestra. En el artículo, se compara la efectividad de la prueba con otros procedimientos estadísticos como la prueba χ^2 , la prueba de Kolmogorov-Smirnov y algunas más. En el capítulo tercero se describirán con más detalle los resultados del artículo, agregando los respectivos de la modificación que se propone en este trabajo.

La modificación a la estadística de Shapiro - Wilk, consiste en substituir el estimador de Lloyd $\hat{T}^{(n)}$, por otro cuyo comportamiento estadístico es muy parecido y que además presenta ciertas ventajas de índole asintótico y computacional. Las principales propiedades de este nuevo estimador, al cual denotaremos por $\hat{T}_0^{(n)}$ son:

- 1) Es una combinación lineal de las estadísticas de orden (propiedad compartida por $\hat{T}^{(n)}$).
- 2) Es un estimador insesgado del parámetro de escala σ . (propiedad compartida por $\hat{T}^{(n)}$).
- 3) Debido a que su derivación descansa básicamente en la teoría de estadísticas U de Hoeffding, posee una distribución asintótica.
- 4) Existe un procedimiento recursivo por medio del cual es posible calcularlo para cualquier tamaño de muestra, sin depender del uso de tablas.

En las dos primeras secciones de este capítulo se discutirán la derivación de $\hat{T}_0^{(n)}$ y sus características estadísticas. Seguidamente serán expuestas las simulaciones respectivas, de la distribución nula y de la potencia.

a) DERIVACIÓN DEL ESTIMADOR $\hat{\mu}^{(n)}$

Comenzamos recordando el concepto clásico de: "estadística U" de Hoeffding:

Sea D un conjunto de funciones de distribución, definidas en \mathbb{R}^k .

Sea $\mathcal{Q}: D \rightarrow \mathbb{R}$ una funcional definida en D .

Decimos que \mathcal{Q} es una funcional regular en D , si y solo si:

$$\exists \underbrace{\Phi: \mathbb{R}^k \times \dots \times \mathbb{R}^k \rightarrow \mathbb{R}}_{n \text{ veces}} \quad \forall \underbrace{F \in D}_{\text{muestra aleatoria de } F} \quad \forall \underline{x}_1, \dots, \underline{x}_n \quad \mathbb{E}[\Phi(\underline{x}_1, \dots, \underline{x}_n)] = \mathcal{Q}(F)$$

A la función Φ , se le denomina el kernel de \mathcal{Q} , si además se cumple que n es el grado de \mathcal{Q} en D , es decir si n es el mínimo natural para el cual se satisface la proposición.

Por otro lado, si $\underline{x}_1, \dots, \underline{x}_n$ son n vectores aleatorios de dimensión k y

$$\Phi: \underbrace{\mathbb{R}^k \times \dots \times \mathbb{R}^k}_{m \text{ veces}} \rightarrow \mathbb{R} \quad \text{una función,}$$

podemos definir una estadística de la siguiente forma:

$$U: \mathbb{R}^k \times \dots \times \mathbb{R}^k \rightarrow \mathbb{R}$$

$$\underline{x}_1, \dots, \underline{x}_n \rightarrow \frac{1}{\binom{n}{m} m!} \sum'' \Phi(\underline{x}_{i_1}, \dots, \underline{x}_{i_m})$$

donde \sum'' , es la suma sobre todas las permutaciones posibles de m índices.

La estadística U , es simétrica en X_1, \dots, X_n y se conoce como una estadística- U de Hoeffding. Cuando Φ es el kernel de una funcional regular definida en un conjunto \mathcal{D} de funciones de distribución k -dimensionales, claramente U es un estimador sesgado de Φ en \mathcal{D} , ya que de la definición se tiene:

18

$$\forall F \in \mathcal{D} \quad \Phi(F) = \int \dots \int_{\underbrace{\mathbb{R}^k \times \dots \times \mathbb{R}^k}_{n \text{ veces}}} U(x_1, \dots, x_n) dF(x_1) \dots dF(x_n)$$

Así pues, cuando $r=1$, $\mathcal{D} = \{N(\mu, \sigma^2), \mu \in \mathbb{R}, \sigma \in \mathbb{R}^+\}$, la funcional:

$$\begin{aligned} \Phi: \mathcal{D} &\rightarrow \mathbb{R} \\ N(\mu, \sigma^2) &\rightarrow \sigma \end{aligned}$$

es regular en \mathcal{D} , puesto que al tomar $n=2$ y

$$\begin{aligned} \varphi: \mathbb{R} \times \mathbb{R} &\rightarrow \mathbb{R} \\ (x_1, x_2) &\rightarrow k|x_1 - x_2| \end{aligned}$$

con $k = \frac{\sqrt{\pi}}{2}$, tenemos que si $F \in \mathcal{D}$

y X_1, X_2 es una muestra aleatoria de F , entonces:

$$\begin{aligned} \mathbb{E}[\varphi(X_1, X_2)] &= \mathbb{E}[k|X_1 - X_2|] \\ &= \sigma, \end{aligned}$$

ya que si

$$Y_i = \frac{X_i - \mu}{\sigma} \quad i=1, 2$$

$Y_i \sim N(0,1)$ y por tanto:

19

$$\begin{aligned} E[k | X_1 - X_2] &= E[k | (\mu + \sigma Y_1) - (\mu + \sigma Y_2)] \\ &= E[k | \sigma Y_1 - \sigma Y_2] \\ &= k\sigma E[|Y_1 - Y_2|] \end{aligned}$$

Tomando $Z = Y_1 - Y_2$ y notando que $Z \sim N(0,2)$ tenemos:

$$\begin{aligned} E[|Y_1 - Y_2|] &= E[|Z|] = \int_{-\infty}^{\infty} |z| \frac{1}{\sqrt{2}\sqrt{2\pi}} e^{-\frac{1}{2(2)}z^2} dz \\ &= \frac{2}{\sqrt{\pi}} = k^{-1} \end{aligned}$$

$$\therefore E[\Phi(X_1, X_2)] = k\sigma k^{-1} = \sigma$$

Como además con una muestra de tamaño uno, no es posible estimar la desviación-estándar σ , de una distribución normal, Φ es el kernel de Θ con grado dos. Por tal motivo, si X_1, \dots, X_n es una muestra aleatoria de una $N(\mu, \sigma^2)$, la estadística-U basada en este kernel es:

$$U = U(X_1, \dots, X_n) = \frac{1}{\binom{n}{2} 2!} \sum_{i < j} k |X_i - X_j|$$

Esta estadística-U es precisamente el estimador $\hat{\sigma}_U^{(n)}$ propuesto. A continuación veremos que es una combinación lineal de las estadísticas de orden, y el método recursivo que facilita su cálculo.

Recordará el lector que si X_1, \dots, X_n es una muestra aleatoria de $F_X(\cdot)$, función de distribución, y $\varphi: \mathbb{R}^m \rightarrow \mathbb{R}$ con $m \leq n$ una función $\rightarrow \varphi(X_1, \dots, X_m)$ sea variable aleatoria, entonces:

$$\mathbb{E}[\varphi(X_1, \dots, X_m) \mid X_{(1)}^{(n)}, \dots, X_{(n)}^{(n)}] = \frac{1}{\binom{n}{m} m!} \sum'' \varphi(X_{i_1}, \dots, X_{i_m})$$

donde \sum'' es la suma sobre todas las permutaciones de m elementos (i_1, \dots, i_m) del conjunto de índices $\{1, \dots, n\}$. Por tanto,

$$\begin{aligned} U(X_1, \dots, X_n) &= \frac{1}{\binom{n}{2} 2!} \sum_{i \neq j} k |X_i - X_j| \\ &= \mathbb{E}[k |X_1 - X_2| \mid X_{(1)}^{(n)}, \dots, X_{(n)}^{(n)}] \end{aligned}$$

es decir:

$$\hat{J}_U^{(n)} = \mathbb{E}[k |X_1 - X_2| \mid X_{(1)}^{(n)}, \dots, X_{(n)}^{(n)}]$$

$$\text{con } k = \sqrt{n}/2.$$

Si observamos ahora que las n -estadísticas de orden $X_{(1)}^{(n)}, \dots, X_{(n)}^{(n)}$, quedan completamente determinadas por el conocimiento de $X_{(1)}^{(n-1)}, \dots, X_{(n-1)}^{(n-1)}$ y X_n , es decir que:

$$\sigma(X_{(1)}^{(n)}, \dots, X_{(n)}^{(n)}) \subset \sigma(X_{(1)}^{(n-1)}, \dots, X_{(n-1)}^{(n-1)}, X_n)$$

donde $\sigma\{X_i\}_{i \in I}$ es el mínimo σ -álgebra \rightarrow .

$\forall X_i$ es medible, obtenemos:

$\in \mathbb{I}$

$$\begin{aligned} & \mathbb{E} [k | X_1 - X_2 | \mid X_{(1)}^{(n)}, \dots, X_{(n)}^{(n)}] \\ &= \mathbb{E} \left[\mathbb{E} [k | X_1 - X_2 | \mid X_{(1)}^{(n)}, \dots, X_{(n-1)}^{(n)}, X_n] \mid X_{(1)}^{(n)}, \dots, X_{(n)}^{(n)} \right] \end{aligned}$$

Ahora dado que $X_{(1)}^{(n)}, \dots, X_{(n-1)}^{(n)}$ es independiente de X_n y $k | X_1 - X_2 |, X_{(1)}^{(n)}, \dots, X_{(n-1)}^{(n)}$ es independiente de X_n , se tiene:

$$\mathbb{E} [k | X_1 - X_2 | \mid X_{(1)}^{(n)}, \dots, X_{(n-1)}^{(n)}, X_n] = \mathbb{E} [k | X_1 - X_2 | \mid X_{(1)}^{(n)}, \dots, X_{(n-1)}^{(n)}]$$

Esta última igualdad es de vital importancia para la derivación del método recursivo que permite el cálculo fácil de $\hat{\sigma}_U^{(n)}$, por lo que se incluye en el Apéndice B una demostración completa de la misma.

Usando ambas afirmaciones obtenemos:

$$\begin{aligned} \hat{\sigma}_U^{(n)} &= \mathbb{E} [k | X_1 - X_2 | \mid X_{(1)}^{(n)}, \dots, X_{(n)}^{(n)}] \\ &= \mathbb{E} \left[\mathbb{E} [k | X_1 - X_2 | \mid X_{(1)}^{(n)}, \dots, X_{(n-1)}^{(n)}, X_n] \mid X_{(1)}^{(n)}, \dots, X_{(n)}^{(n)} \right] \\ &= \mathbb{E} \left[\mathbb{E} [k | X_1 - X_2 | \mid X_{(1)}^{(n)}, \dots, X_{(n-1)}^{(n)}] \mid X_{(1)}^{(n)}, \dots, X_{(n)}^{(n)} \right] \\ &= \mathbb{E} \left[\hat{\sigma}_U^{(n-1)} \mid X_{(1)}^{(n)}, \dots, X_{(n)}^{(n)} \right] \end{aligned}$$

es decir: $\hat{\sigma}_U^{(n)} = \mathbb{E} \left[\hat{\sigma}_U^{(n-1)} \mid X_{(1)}^{(n)}, \dots, X_{(n)}^{(n)} \right].$

Esta es, finalmente, la fórmula recursiva.

Así pues, para $n=2$:

$$\begin{aligned}
 \hat{\sigma}_U^{(2)} &= \mathbb{E} [k |X_1 - X_2| \mid X_{(1)}^{(2)}, X_{(2)}^{(2)}] \\
 &= \mathbb{E} [k (X_{(2)}^{(2)} - X_{(1)}^{(2)}) \mid X_{(1)}^{(2)}, X_{(2)}^{(2)}] \\
 &= k X_{(2)}^{(2)} - k X_{(1)}^{(2)} \\
 &= (-k, k) \begin{pmatrix} X_{(1)}^{(2)} \\ X_{(2)}^{(2)} \end{pmatrix} = \underline{b}^{(2)'} \underline{X}^{(2)}
 \end{aligned}$$

Para $n=3$:

$$\begin{aligned}
 \hat{\sigma}_U^{(3)} &= \mathbb{E} [k |X_1 - X_2| \mid X_{(1)}^{(3)}, X_{(2)}^{(3)}, X_{(3)}^{(3)}] \\
 &= \mathbb{E} [\hat{\sigma}_U^{(2)} \mid X_{(1)}^{(3)}, X_{(2)}^{(3)}, X_{(3)}^{(3)}] \\
 &= \mathbb{E} [\underline{b}^{(2)'} \underline{X}^{(2)} \mid X_{(1)}^{(3)}, X_{(2)}^{(3)}, X_{(3)}^{(3)}]
 \end{aligned}$$

Dados $X_{(1)}^{(3)}, X_{(2)}^{(3)}, X_{(3)}^{(3)}$

$$X_{(1)}^{(2)} \text{ pudo ser } \begin{cases} X_{(1)}^{(3)} & \text{con prob. } \frac{2}{3} \\ \sigma & \\ X_{(2)}^{(3)} & \text{con prob. } \frac{1}{3} \end{cases}$$

De igual forma:

$$X_{(2)}^{(2)} \text{ pudo ser } \begin{cases} X_{(2)}^{(3)} & \text{con prob. } \frac{1}{3} \\ \sigma & \\ X_{(3)}^{(3)} & \text{con prob. } \frac{2}{3} \end{cases}$$

de donde

$$\hat{\sigma}_U^{(3)} = \mathbb{E} [k X_{(2)}^{(2)} - k X_{(1)}^{(2)} \mid X_{(1)}^{(3)}, X_{(2)}^{(3)}, X_{(3)}^{(3)}]$$

$$\begin{aligned}
&= k \left(\frac{1}{3} X_{(2)}^{(3)} + \frac{2}{3} X_{(3)}^{(3)} \right) \\
&\quad - k \left(\frac{2}{3} X_{(1)}^{(3)} + \frac{1}{3} X_{(2)}^{(3)} \right) \\
&= -\frac{2}{3} k X_{(1)}^{(3)} + \frac{2}{3} k X_{(3)}^{(3)} \\
&= \left(-\frac{2}{3} k, 0, \frac{2}{3} k \right) \begin{pmatrix} X_{(1)}^{(3)} \\ X_{(2)}^{(3)} \\ X_{(3)}^{(3)} \end{pmatrix} \\
&= \left[\begin{pmatrix} \frac{2}{3} & 0 \\ 0 & \frac{2}{3} \end{pmatrix} \begin{pmatrix} -k \\ k \end{pmatrix} \right]' \begin{pmatrix} X_{(1)}^{(3)} \\ X_{(2)}^{(3)} \\ X_{(3)}^{(3)} \end{pmatrix} \\
&= \underline{b}^{(3)'} \underline{X}^{(3)}
\end{aligned}$$

$$\begin{aligned}
\text{donde } \underline{b}^{(3)} &= \begin{pmatrix} \frac{2}{3} & 0 \\ \frac{1}{3} & \frac{1}{3} \\ 0 & \frac{2}{3} \end{pmatrix} \underline{b}^{(2)} \\
&= A_3 \underline{b}^{(2)}
\end{aligned}$$

es decir: $\hat{\sigma}_U^{(3)} = (A_3 \underline{b}^{(2)})' \underline{X}^{(3)}$

Para $n=4$

$$\hat{\sigma}_U^{(4)} = E \left[\hat{\sigma}_U^{(3)} \mid X_{(1)}^{(4)}, X_{(2)}^{(4)}, X_{(3)}^{(4)}, X_{(4)}^{(4)} \right]$$

$$\hat{\sigma}_v^{(4)} = \mathbb{E} \left[\underline{b}_3' \underline{X}_{(3)} \mid X_{(1)}^{(4)}, X_{(2)}^{(4)}, X_{(3)}^{(4)}, X_{(4)}^{(4)} \right]$$

$$= \mathbb{E} \left[-\frac{2}{3}kX_{(1)}^{(3)} + \frac{2}{3}kX_{(3)}^{(3)} \mid X_{(1)}^{(4)}, X_{(2)}^{(4)}, X_{(3)}^{(4)}, X_{(4)}^{(4)} \right]$$

Ahora

$$X_{(1)}^{(3)} \text{ puede ser } \begin{cases} X_{(1)}^{(4)} & \text{con } \frac{3}{4} \text{ de prob.} \\ 0 & \\ X_{(2)}^{(4)} & \text{con } \frac{1}{4} \text{ de prob.} \end{cases}$$

$$X_{(2)}^{(3)} \text{ puede ser } \begin{cases} X_{(2)}^{(4)} & \text{con } \frac{2}{4} \text{ de prob.} \\ 0 & \\ X_{(3)}^{(4)} & \text{con } \frac{2}{4} \text{ de prob.} \end{cases}$$

$$X_{(3)}^{(3)} \text{ puede ser } \begin{cases} X_{(3)}^{(4)} & \text{con } \frac{1}{4} \text{ de prob.} \\ 0 & \\ X_{(4)}^{(4)} & \text{con } \frac{3}{4} \text{ de prob.} \end{cases}$$

$$\therefore \mathbb{E} \left[X_{(1)}^{(3)} \mid \mathcal{Q}_4 \right] = \frac{3}{4} X_{(1)}^{(4)} + \frac{1}{4} X_{(2)}^{(4)}$$

$$\mathbb{E} \left[X_{(3)}^{(3)} \mid \mathcal{Q}_4 \right] = \frac{1}{4} X_{(3)}^{(4)} + \frac{3}{4} X_{(4)}^{(4)}$$

$$\hat{\sigma}_v^{(4)} = -\frac{2}{3}k \left(\frac{3}{4} X_{(1)}^{(4)} + \frac{1}{4} X_{(2)}^{(4)} \right)$$

$$+ \frac{2}{3}k \left(\frac{1}{4} X_{(3)}^{(4)} + \frac{3}{4} X_{(4)}^{(4)} \right)$$

$$= \left((-k) \frac{2}{3} \cdot \frac{3}{4}, (-k) \frac{2}{3} \cdot \frac{1}{4}, (k) \frac{2}{3} \cdot \frac{1}{4}, (k) \frac{2}{3} \cdot \frac{3}{4} \right) \underline{X}_{(4)}$$

$$= \underline{b}_4' \underline{X}_{(4)}$$

Teniendo $A_4 = \begin{pmatrix} 3/4 & 0 & 0 \\ 1/4 & 3/4 & 0 \\ 0 & 1/4 & 1/4 \\ 0 & 0 & 3/4 \end{pmatrix}$

25

$$A_4 A_3 \underline{b}_2 = \begin{pmatrix} 3/4 & 0 & 0 \\ 1/4 & 3/4 & 0 \\ 0 & 1/4 & 1/4 \\ 0 & 0 & 3/4 \end{pmatrix} \begin{pmatrix} 2/3 & 0 \\ 1/3 & 1/3 \\ 0 & 2/3 \end{pmatrix} \begin{pmatrix} -k \\ k \end{pmatrix}$$

$$= \begin{pmatrix} \frac{2}{3} & & & 0 \\ \frac{1}{4} \cdot \frac{2}{3} + \frac{2}{4} \cdot \frac{1}{3} & \frac{2}{4} \cdot \frac{1}{3} & & \\ \frac{2}{4} \cdot \frac{1}{3} & \frac{2}{4} \cdot \frac{1}{3} + \frac{1}{4} \cdot \frac{2}{3} & & \\ 0 & \frac{2}{3} \cdot \frac{2}{4} & & \end{pmatrix} \begin{pmatrix} -k \\ k \end{pmatrix}$$

$$= \underline{b}_4$$

ie $\underline{b}_4 = A_4 \underline{b}_3 = A_4 A_3 \underline{b}_2$

$$\therefore \hat{T}_U^{(4)} = (A_4 A_3 \underline{b}_2)' \underline{X}^{(4)}$$

Para el caso general:

Teniendo $X_{(1)}^{(n-1)}, \dots, X_{(n-1)}^{(n-1)}$; la nueva observación X_n cae en intervalos de la forma

$$X_{(j-1)}^{(n-1)} < X_n \leq X_{(j)}^{(n-1)} \quad j=1, \dots, n$$

entonces $X_{(1)}^{(n)}, \dots, X_{(n)}^{(n)}$ se transforma en:

$$X_{(i)}^{(n)} = \begin{cases} X_{(i)}^{(n-1)} & \text{si } i < j \\ X_n & \text{si } i = j \\ X_{(i-1)}^{(n-1)} & \text{si } i > j \end{cases}$$

Por tanto, dados $X_{(i)}^{(n)}, \dots, X_{(n)}^{(n)}$

26

$X_{(i)}^{(n-1)}$ puede ser $X_{(i)}^{(n)}$ si $X_n = X_{(i)}^{(n)}$
con $j > i$

Hay $n-i$ de estos casos

$X_{(i)}^{(n-1)}$ puede ser $X_{(j)}^{(n)}$ si $X_n = X_{(j)}^{(n)}$
con $j \leq i$

Hay i de estos casos

$$X_{(i)}^{(n-1)} = \begin{cases} X_{(i)}^{(n)} & \text{con prob } \frac{n-i}{n} \\ X_{(j)}^{(n)} & \text{con prob } \frac{i}{n} \end{cases}$$

Así pues

$$\mathbb{E} \left[X_{(i)}^{(n-1)} \mid X_{(i)}^{(n)}, \dots, X_{(n)}^{(n)} \right]$$

$$= \frac{n-i}{n} X_{(i)}^{(n)} + \frac{i}{n} X_{(i+1)}^{(n)}$$

$$\dots \mathbb{E} \left[\sum_{i=1}^n b_{n-1} X_{(i)}^{(n-1)} \mid \mathcal{Q}_n \right] = \mathbb{E} \left[\sum_{i=1}^n b_i X_{(i)}^{(n-1)} \mid X_{(1)}^{(n)}, \dots, X_{(n)}^{(n)} \right]$$

$$= \sum_{i=1}^n b_i \left(\frac{n-i}{n} X_{(i)}^{(n)} + \frac{i}{n} X_{(i+1)}^{(n)} \right)$$

$$= \sum_{i=1}^n \left(b_i \frac{n-i}{n} X_{(i)}^{(n)} + b_i \frac{i}{n} X_{(i+1)}^{(n)} \right)$$

$$= b_1 \frac{n-1}{n} X_{(1)}^{(n)} + \sum_{i=2}^{n-1} \left(b_i \frac{n-i}{n} + b_{i-1} \frac{i-1}{n} \right) X_{(i)}^{(n)} + b_{n-1} \frac{n-1}{n} X_{(n)}^{(n)}$$

27

$$\begin{bmatrix} b_1 \frac{n-1}{n} \\ b_2 \frac{n-2}{n} + b_1 \frac{1}{n} \\ b_3 \frac{n-3}{n} + b_2 \frac{2}{n} \\ \vdots \\ b_{n-2} \frac{2}{n} + b_{n-3} \frac{n-3}{n} \\ b_{n-1} \frac{1}{n} + b_{n-2} \frac{n-2}{n} \\ b_{n-1} \frac{n-1}{n} \end{bmatrix}$$

$$\underline{X}^{(n)} = \underline{b}^{(n)} \underline{X}^{(n)}$$

Notando ahora que $\underline{b}^{(n)}$ se puede expresar como:

$$\begin{bmatrix} n-1/n & 0 & 0 & \dots & 0 & 0 & 0 \\ 1/n & n-2/n & 0 & \dots & 0 & 0 & 0 \\ 0 & 2/n & n-3/n & \dots & 0 & 0 & 0 \\ 0 & 0 & 3/n & \dots & 0 & 0 & 0 \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & \dots & 3/n & 0 & 0 \\ 0 & 0 & 0 & \dots & n-3/n & 2/n & 0 \\ 0 & 0 & 0 & \dots & 0 & n-2/n & 1/n \\ 0 & 0 & 0 & \dots & 0 & 0 & n-1/n \end{bmatrix} \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_{n-2} \\ b_{n-1} \end{bmatrix} = \underline{b}^{(n)}$$

$$= A_n \underline{b}^{(n)}$$

Tenemos que:

$$\mathbb{E} [\underline{\hat{u}}^{(n)} | \underline{O}_n] = (A_n \underline{b}_{n-1})' \underline{X}_{(n)}$$

∴ continuando con el cálculo recursivo de \hat{u} :

Para $n=5$

$$\underline{\hat{u}}^{(5)} = \mathbb{E} [\underline{\hat{u}}^{(4)} | \underline{O}_5]$$

$$= \mathbb{E} [\underline{b}'_4 \underline{X}_{(4)} | \underline{O}_5]$$

$$= (A_5 \underline{b}'_4)' \underline{X}_{(5)}$$

pero como

$$\underline{b}'_4 = (A_4 A_3 \underline{b}'_2)'$$

$$\underline{\hat{u}}^{(5)} = (A_5 A_4 A_3 \underline{b}'_2)' \underline{X}_{(5)} = \underline{b}'_{(5)} \underline{X}_{(5)}$$

Hasta que finalmente

$$\underline{\hat{u}}^{(n)} = \underline{b}'_n \underline{X}_{(n)}$$

$$= (A_n^* A_{n-1} \times \dots \times A_3 \underline{b}'_2)' \underline{X}_{(n)}$$

con $\underline{b}_2 = \begin{pmatrix} -k \\ k \end{pmatrix}$ $k = \frac{\sqrt{n}}{2}$

y A_i , matriz de $x(i)$ =

$$\begin{pmatrix} \frac{1}{r_1} & 0 & 0 & \dots & 0 & 0 & 0 \\ 0 & \frac{1}{r_2} & 0 & \dots & 0 & 0 & 0 \\ 0 & 0 & \frac{1}{r_3} & \dots & 0 & 0 & 0 \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & \dots & 0 & 0 & 0 \\ 0 & 0 & 0 & \dots & 0 & 0 & 0 \\ 0 & 0 & 0 & \dots & 0 & 0 & 0 \end{pmatrix}$$

$$(A_n^*)_{lk} = \begin{cases} n-l & \text{Para } k=l \text{ con } l=1, \dots, n-1 \\ l-1 & \text{Para } k=l-1 \text{ con } l=2, \dots, n \\ 0 & \text{en otro caso con } l=1, \dots, n \text{ y } \\ & k=1, \dots, n-1 \end{cases} \quad 30$$

$$y \quad (\Pi_{n-1})_{ki} = \begin{cases} (n-1)-k & \text{para } l=1, k=1, \dots, n-1 \\ k-1 & \text{para } l=2, k=1, \dots, n-1 \end{cases}$$

Por tanto; para $i=2, \dots, n-1$

$$\begin{aligned} (A_n^* \Pi_{n-1})_{i1} &= (A_n^*)_{i,i-1} (\Pi_{n-1})_{i-1,1} + \\ &\quad (A_n^*)_{i,i} (\Pi_{n-1})_{i,1} \\ &= (i-1)(n-i) + (n-i)(n-1-i) \\ &= (n-i)(i-1+n-i-i) \\ &= (n-i)(n-2) \end{aligned}$$

$$\begin{aligned} (A_n^* \Pi_{n-1})_{i2} &= (A_n^*)_{i,i-1} (\Pi_{n-1})_{i-1,2} \\ &\quad + (A_n^*)_{i,i} (\Pi_{n-1})_{i,2} \\ &= (i-1)((i-1)-1) + (n-i)(i-1) \\ &= (i-1)(i-2+n-i) = \\ &= (i-1)(n-2) \end{aligned}$$

$$y \quad (A_n^* \Pi_{n-1})_{11} = (n-1)(n-2) \quad (A_n^* \Pi_{n-1})_{12} = 0$$

$$(A_n^* \Pi_{n-1})_{n1} = 0 \quad (A_n^* \Pi_{n-1})_{n2} = (n-1)(n-2)$$

ie

$$(A_n^* \Pi_{n-1}) = \begin{pmatrix} (n-1)(n-2) & 0 \\ (n-2)(n-2) & 2(n-2) \\ (n-3)(n-2) & 2(n-2) \\ \vdots & \vdots \\ 2(n-2) & (n-3)(n-2) \\ 2(n-2) & (n-2)(n-2) \\ 0(n-2) & (n-1)(n-2) \end{pmatrix}$$

31

ie

$$(A_n^* \Pi_{n-1}) = \begin{pmatrix} n-1 & 0 \\ n-2 & 1 \\ n-3 & 2 \\ \vdots & \vdots \\ 2 & n-3 \\ 1 & n-2 \\ 0 & n-1 \end{pmatrix}$$

Así pues:

$$\hat{b}^{(n)} = \frac{2}{n(n-1)} \begin{pmatrix} n-1 & 0 \\ n-2 & 1 \\ \vdots & \vdots \\ 2 & n-2 \\ 0 & n-1 \end{pmatrix} \begin{pmatrix} -k \\ k \end{pmatrix}$$

ie

$$\hat{b}^{(n)} = \frac{2k}{n(n-1)} \begin{pmatrix} 1-n \\ 3-n \\ 5-n \\ \vdots \\ n-5 \\ n-3 \\ 1 \end{pmatrix} \text{ con } k = \frac{\sqrt{n}}{2}$$

Por tanto, la expresión de $\hat{b}^{(n)}$ como combina-

ción lineal de las n estadísticas de orden, es: 32

$$\hat{\sigma}_U^{(n)} = b^{(n)'} \underline{X}^{(n)} = \frac{\sqrt{\pi}}{n(n-1)} \begin{pmatrix} 1-n \\ 3-n \\ 5-n \\ \vdots \\ n-5 \\ n-3 \\ n-1 \end{pmatrix} \underline{X}^{(n)}$$

$$= \frac{\sqrt{\pi}}{n(n-1)} \sum_{i=1}^n (2i - (n+1)) X_{(i)}$$

Comparando estas expresiones con las correspondientes a $\hat{\sigma}^{(n)}$, podemos parcartanos de la simplicidad de $\hat{\sigma}_U^{(n)}$; su cálculo es muy sencillo y fácil de efectuar, lo que unido a sus propiedades asintóticas, concede a la modificación ciertas ventajas sobre otros métodos estadísticos.

b) PROPIEDADES ANALÍTICAS Y ASINTÓTICAS DEL ESTIMADOR $\hat{\sigma}_U^{(n)}$.

Dando por asentada la naturaleza estadística del estimador $\hat{\sigma}_U^{(n)}$, como una estadística-U, podemos determinar su varianza y distribución asintótica a través de la teoría de Hoeffding.

Según dicha teoría, la varianza de una estadística-U:

$$U = \binom{n}{m}^{-1} \sum^m \phi(x_{i_1}, \dots, x_{i_m})$$

33

basada en el kernel simétrico ϕ de una funcional lineal Θ , con x_1, \dots, x_n muestra aleatoria, esta dada por:

$$\text{Var}(U) = \binom{n}{m}^{-1} \sum_{c=1}^m \binom{m}{c} \binom{n-m}{m-c} \zeta_c$$

donde:

$$\zeta_c = \mathbb{E}[\Phi_c^2(x_1, \dots, x_c)] - \Theta^2$$

$$\text{y } \Phi_c(x_1, \dots, x_c) = \mathbb{E}[\phi(x_1, \dots, x_c, x_{c+1}, \dots, x_m)].$$

Por tanto:

$$\text{Var}(\hat{f}_U^{(n)}) = \frac{2}{n(n-1)} [2(n-2)\zeta_1^{(1)} - \zeta_2^{(1)}]$$

$$\text{con } \zeta_1^{(1)} = \mathbb{E}[\Phi_1^{(1)}(x_1)]^2 - \sigma^2$$

$$\text{y } \zeta_2^{(1)} = \mathbb{E}[\Phi_2^{(1)}(x_1, x_2)]^2 - \sigma^2$$

Ahora como $\Phi^{(1)}(x_1, x_2) = k|x_1 - x_2|$

$$\Phi_1^{(1)}(x_1) = \mathbb{E}[\phi(x_1, x_2)] = \mathbb{E}[k|x_1 - x_2|]$$

$$= \int_{-\infty}^{\infty} k|x_1 - x_2| \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2\sigma^2}(x_2 - \mu)^2} dx_2$$

puesto que $x_2 \sim N(\mu, \sigma^2)$

de donde:

34

$$\mathbb{E}[\Phi_1^{(1)}(x_1)]^2 =$$

$$\int_{-\infty}^{\infty} \left(\int_{-\infty}^{\infty} k|x_1-x_2| \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2\sigma^2}(x_2-\mu)^2} dx_2 \right)^2 \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2\sigma^2}(x_1-\mu)^2} dx_1$$

$$= \left(\frac{\pi}{12} + \frac{\sqrt{3}}{2} \right) \sigma^2 \quad (\text{Ver anexo D, (1)})$$

$$\therefore \gamma_1^{(4)} = \left(\frac{\pi}{12} + \frac{\sqrt{3}}{2} - 1 \right) \sigma^2$$

$$\cong .127824792 \sigma^2$$

De igual forma:

$$\Phi_1^{(2)}(x_1, x_2) = k|x_1-x_2|$$

$$\therefore \mathbb{E}[\Phi_1^{(2)}(x_1, x_2)]^2 = \mathbb{E}[k^2(x_1-x_2)^2]$$

$$= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} k^2(x_1-x_2)^2 \frac{1}{2\pi\sigma^2} e^{-\frac{1}{2\sigma^2}[(x_1-\mu)^2 + (x_2-\mu)^2]} dx_1 dx_2$$

$$= \frac{\pi}{2} \sigma^2 \quad \therefore \gamma_2^{(1)} = \left(\frac{\pi}{2} - 1 \right) \sigma^2$$

\(\therefore\) finalmente:

$$\text{Var}(\hat{\sigma}_v^{(n)}) = \frac{2}{n(n-1)} \left[2(n-2) \left(\frac{\pi}{12} + \frac{\sqrt{3}}{2} - 1 \right) \sigma^2 - \left(\frac{\pi}{2} - 1 \right) \sigma^2 \right]$$

$$= \left[\frac{4(n-2)}{n(n-1)} \left(\frac{\pi}{12} + \frac{\sqrt{3}}{2} - 1 \right) - \frac{2}{n(n-1)} \left(\frac{\pi}{2} - 1 \right) \right] \sigma^2$$

De aquí que:

35

$$\begin{aligned}\lim_{n \rightarrow \infty} n \text{Var}(\hat{\sigma}_U^{(n)}) &= 4 \left(\frac{\pi}{12} + \frac{\sqrt{3}}{2} - 1 \right) \sigma^2 \\ &= m^2 \xi_1^{(4)} = 4 \xi_1^{(4)}\end{aligned}$$

Siguiendo en la misma línea, si aplicamos ahora el teorema 7.2 del apéndice C, obtenemos la distribución asintótica de $\hat{\sigma}_U^{(n)}$:

7.2 nos dice que:

$$\lim_{n \rightarrow \infty} \sqrt{n} (\hat{\sigma}_U^{(n)} - \sigma) \xrightarrow{D} N(0, 4 \xi_1^{(4)})$$

esto es, para n suficientemente grande:

$$\hat{\sigma}_U^{(n)} \sim N\left(\sigma, \frac{4 \xi_1^{(4)}}{n}\right)$$

$$\text{ie } \hat{\sigma}_U^{(n)} \sim N\left(\sigma, \frac{.5113}{n} \sigma^2\right)$$

Por lo que $\hat{\sigma}_U^{(n)}$, es un estimador insesgado, consistente y con distribución asintótica normal, lo cual le da ciertas ventajas sobre otros estimadores de la desviación estándar σ .

C) ESTRUCTURA Y CARACTERÍSTICAS DE LA ESTADÍSTICA PROPUESTA.

Una vez establecida la naturaleza estadística del estimador $\hat{\sigma}_U^{(n)}$, entraremos de lleno a la discusión de la modificación -

propuesta, valiéndonos para ello de toda la información contenida en las secciones anteriores.

36

Se mencionó en el principio de este capítulo que la modificación propuesta, consiste en cambiar el numerador de la estadística de Shapiro-Wilk, el cuadrado del estimador de Lloyd del parámetro de escala σ , por el cuadrado de la estadística-U $\hat{\sigma}_U^{(n)}$, la cual es también una combinación lineal de las estadísticas de orden y un estimador viscosgado de σ . Así pues, la modificación propuesta, denotada por el símbolo $W_U^{(n)}$, es:

$$\begin{aligned} W_U^{(n)} &:= \frac{(\hat{\sigma}_U^{(n)})^2}{S^2} = \frac{(\underline{b}^{(n)'}\underline{x}^{(n)})^2}{S^2} \\ &= \frac{\pi \left[\sum_{i=1}^n (2i-n+1)x_{(i)} \right]^2}{[n(n+1)]^2 \cdot \sum_{i=1}^n \frac{(x_i - \bar{x})^2}{n-1}} \end{aligned}$$

Es de esencial importancia el notar que el estimador robusto de la varianza, S^2 , es una estadística-U basada en el kernel-simétrica de tamaño dos:

$$\varphi^{(2)}(x_1, x_2) = \frac{(x_1 - x_2)^2}{2}$$

de la funcional regular de grado dos:

$\mathcal{O}^{(2)}(F) = \text{Var}(F) = \sigma^2$, definida en el conjunto de todas las familias de distribución unidimensionales con varianza finita.

Es decir:

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$$

37

$$= \binom{n}{2}^{-1} \sum_{i < j} \frac{(x_i - x_j)^2}{2}$$

y \forall F función de distribución unidimensional con varianza finita \forall x_1, x_2, \dots, x_n muestra aleatoria de F $E(S^2) = \sigma^2$

Haciendo uso nuevamente de la teoría de Hoeffding, tenemos:

$$\text{Var}(S^2) = \frac{2}{n(n-1)} \left[2(n-2) \zeta_1^{(2)} + \zeta_2^{(2)} \right]$$

donde

$$\zeta_1^{(2)} = E \left[\Phi_1^{(2)}(x_1) \right]^2 - (\sigma^2)^2$$

$$y \quad \zeta_2^{(2)} = E \left[\Phi_2^{(2)}(x_1, x_2) \right]^2 - (\sigma^2)^2$$

$$\begin{aligned} \text{Como } \Phi_1^{(2)}(x_1) &= E \left[\Phi^{(2)}(x_1, x_2) \right] \\ &= E \left[\frac{(x_1 - x_2)^2}{2} \right] \end{aligned}$$

$$\zeta_1^{(2)} = \frac{1}{2} \sigma^4 \quad (\text{Var apéndice D (4)})$$

De manera similar, como

$$\Phi_2^{(2)}(x_1, x_2) = \Phi^{(2)}(x_1, x_2) = \frac{(x_1 - x_2)^2}{2}$$

$$\zeta_2^{(2)} = 2\sigma^4 \quad (\text{Var apéndice D (5)})$$

$$\begin{aligned} \therefore \text{Var}(s^2) &= \frac{2}{n(n-1)} \left[2(n-2) \frac{1}{2} \sigma^4 + 2\sigma^4 \right] & 38 \\ &= \frac{2}{n-1} \sigma^4 \end{aligned}$$

Podemos constatar nuevamente que:

$$\lim_{n \rightarrow \infty} n \text{Var}(s^2) = m^2 \zeta_1^{(2)}$$

$$\begin{aligned} \text{pues } \lim_{n \rightarrow \infty} n \text{Var}(s^2) &= \lim_{n \rightarrow \infty} n \left(\frac{2}{n-1} \sigma^4 \right) \\ &= 2^2 \frac{1}{2} \sigma^4 = m^2 \zeta_1^{(2)} \end{aligned}$$

Aplicando ahora el teorema 7.2 del apéndice C, tenemos:

$$\lim_{n \rightarrow \infty} \sqrt{n} (s^2 - \sigma^2) \xrightarrow{D} N(0, 2\sigma^4)$$

es decir, para n suficientemente grande

$$s^2 \sim N\left(\sigma^2, \frac{2}{n} \sigma^4\right)$$

Lo que nos interesa ahora, es determinar si la modificación propuesta posee o no una distribución asintótica, y si existe, encontrar explícitamente su expresión. Para tales fines, volvamos a hacer mano de la teoría de estadísticas-U. En primera instancia, el teorema 7.2 del apéndice C nos indica la existencia de una distribución conjunta asintótica, para la función de distribución conjunta de $\sqrt{n}(\hat{\sigma}_U^{(n)} - \sigma)$ y -

$\sqrt{n}(S^2 - \sigma^2)$. Tal afirmación nos indica que: 39

$$\sqrt{n} \begin{pmatrix} \hat{\sigma}_U^{(n)} - \sigma \\ S^2 - \sigma^2 \end{pmatrix} \xrightarrow[n \rightarrow \infty]{D} N \left(\begin{pmatrix} 0 \\ 0 \end{pmatrix}, \begin{pmatrix} 4\gamma_1^{(1)}, 4\gamma_1^{(1,2)} \\ 4\gamma_1^{(1,2)}, 4\gamma_2^{(1)} \end{pmatrix} \right)$$

Es decir:

$$\sqrt{n} \begin{pmatrix} \hat{\sigma}_U^{(n)} - \sigma \\ S^2 - \sigma^2 \end{pmatrix} \xrightarrow[n \rightarrow \infty]{D} N \left(\begin{pmatrix} 0 \\ 0 \end{pmatrix}, \begin{pmatrix} 4 \left(\frac{n}{2} + \frac{13}{2} - 1 \right) \sigma^2 & \sigma^3 \\ \sigma^3 & 2\sigma^4 \end{pmatrix} \right)$$

es

$$\sqrt{n} \begin{pmatrix} \hat{\sigma}_U^{(n)} - \sigma \\ S^2 - \sigma^2 \end{pmatrix} \sim N \left(\begin{pmatrix} 0 \\ 0 \end{pmatrix}, \begin{pmatrix} .5112\sigma^2 & \sigma^3 \\ \sigma^3 & 2\sigma^4 \end{pmatrix} \right)$$

para n "grande"

(Los cálculos de $\gamma_1^{(1)}$, $\gamma_1^{(1,2)}$ y $\gamma_2^{(1)}$ se encuentran en el apéndice D (1), (3) y (4))

Es posible determinar la existencia de una distribución asintótica de $W_U^{(n)}$, en base al teorema 7.5 mencionado en el apéndice C. Tal teorema establece las condiciones suficientes para la existencia de una distribución asintótica, de una función $Z = h(U^{(1)}, \dots, U^{(g)})$ donde $U^{(1)}, \dots, U^{(g)}$ son g -estadísticas- U .

Así pues, tomando la función:

$$h(y_1, y_2) = \frac{y_1^2}{y_2} \quad \text{tenemos que:}$$

$$h(\hat{\sigma}_U^{(n)}, S^2) = \frac{(\hat{\sigma}_U^{(n)})^2}{S^2} = W_U^{(n)}$$

Esta función cumple con todas las condicio-

nes del teorema 7.5, por lo que la variable aleatoria 40

$$\begin{aligned} Z &= \sqrt{n} (h(\hat{\sigma}_0^{(n)}, s^2) - h(\sigma, \sigma^2)) \\ &= \sqrt{n} (W_0^{(n)} - 1) \end{aligned}$$

tiene por distribución asintótica una $N(0, \lambda^2)$ con

$$\lambda^2 = 16 \left(\frac{\pi}{12} + \frac{\sqrt{3}}{2} - 1 \right) - 2 \approx .0452$$

Esto es, para n suficientemente grande

$$W_0^{(n)} \sim N\left(1, \frac{.0452}{n}\right)$$

Finalmente, podemos observar que los valores generados por simulación de $W_0^{(n)}$ para $n=40$ y 50 se adecuan en buena medida a la aproximación anterior.

III... SIMULACIONES DE LA DISTRIBUCIÓN NULA DE $W_0^{(n)}$ Y DE SU POTENCIA. 41

Como en el caso de la estadística de Shapiro - Wilk, la complejidad estadística de la modificación propuesta, no ha permitido hasta ahora, el determinar exactamente su distribución nula teórica, por lo que se ha tenido que recurrir a la técnica de la simulación, para obtener una aproximación empírica.

Una vez obtenidas las aproximaciones de los principales percentiles, se simuló su potencia para cuatro tamaños de muestra, muestreando de varias familias de distribución. En las dos primeras secciones de este capítulo, se exponen tales simulaciones, y en la sección tercera se discuten las conclusiones respecto a la efectividad de la modificación propuesta.

a) UNA APROXIMACIÓN A LA DISTRIBUCIÓN NULA DE $W_0^{(n)}$.

El procedimiento usado en la simulación de la distribución nula de $W_0^{(n)}$ a grandes rasgos fue el siguiente:

Paso 1) A través de una subrutina generadora de valores aleatorios independientes de una normal estandarizada, se obtuvieron $M(n)$ muestras aleatorias de tamaño n .

Paso 2) Ordenando las muestras y apli-

cando la expresión algebraica derivada en el capítulo pasado, se calculó el valor correspondiente $W_0^{(n)}$ de todas y cada una de las muestras, generando así, una muestra aleatoria de tamaño $M(n)$ de la distribución nula de $W_0^{(n)}$.

Paso 3) Finalmente, por medio de la distribución empírica de la muestra anterior, se obtuvo una aproximación a los principales percentiles de la distribución nula de $W_0^{(n)}$.

En la tabla I, aparecen las cantidades derivadas por el procedimiento anterior, para tamaños de muestra de 10, 20, 40 y 50. Asimismo, usando la aproximación asintótica a la distribución nula de $W_0^{(n)}$, se encontraron los respectivos percentiles para cada n . Tales valores, se listan también en la tabla I.

Los percentiles simulados difieren muy poco de los correspondientes valores que resultan al usar la aproximación normal mencionada. En la tabla podemos observar que la discrepancia mayor es del orden de seis centésimas; asumiéndose al grado de adecuación a medida que aumenta el tamaño de muestra n .

Dicha similitud se refleja también entre la media y varianza de los percentiles simulados ($\bar{x}(n)s$ y $s^2(n)s$) y la media y varianza de la aproximación normal ($\mu(n)a$ y $\sigma^2(n)a$), resultando aún mucho menor la diferencia en cada caso.

TABLA I. APROXIMACIONES A LA DISTRIBUCIÓN NULA DE $W^{(n)}$.

n	10	20	40	50
$u(n)$	4000	4000	3000	3000
$\cdot 01 s$.82084	.86296	.90890	.92328
$\cdot 01 a$.84342	.88933	.92171	.92987
$\cdot 05 s$.92897	.93367	.94907	.95312
$\cdot 05 a$.88912	.92163	.94456	.95034
$\cdot 10 s$.97191	.96343	.96669	.97078
$\cdot 10 a$.91398	.93920	.95699	.96147
$\cdot 90 s$	1.12256	1.07608	1.04977	1.04413
$\cdot 90 a$	1.08602	1.06080	1.04301	1.03853
$\cdot 95 s$	1.12893	1.08109	1.05508	1.04938
$\cdot 95 a$	1.11088	1.07838	1.05544	1.04967
$\cdot 99 s$	1.13771	1.08764	1.06198	1.05622
$\cdot 99 a$	1.15658	1.11068	1.07829	1.07013
$\bar{x}(n) s$	1.01848	1.0081	.99858	.99949
$\bar{x}(n) a$	1	1	1	1
$s^2(n) s$.01729	.00891	.00427	.00330
$s^2(n) a$.01968	.00884	.00442	.00355
$\mu(n) a$	1	1	1	1
$\sigma^2(n) a$.00451	.00225	.00112	.00090

s - Aproximaciones simuladas
a - Aproximaciones asintóticas

b) Potencia Empírica De $W_0^{(n)}$.

44

Confrontando con las aproximaciones a los principales percentiles de la distribución nula de $W_0^{(n)}$ que determinan las regiones de rechazo de la prueba, valores pequeños de la estadística de prueba, es posible simular su potencia tomando diversas muestras provenientes de varias poblaciones y contando el número de rechazos que ocurren en cada caso. Realizando tal procedimiento un número suficientemente grande de veces, podemos esperar que el porcentaje de rechazos, sea una buena aproximación a la potencia de la prueba.

El tamaño de la simulación fue de 600 para los cuatro tamaños de muestra: $n=10, 20, 40$ y 50 . Las poblaciones muestreadas fueron: $N(0,1)$, $\text{Exp}(10)$, lognormal (1) , $\chi^2(1)$, $\chi^2(2)$, $\chi^2(4)$, $\chi^2(10)$, Binomial $(4, 1/2)$ y Poisson (1) .

Shapiro y Wilk, de manera similar, simularon también la potencia de su prueba al 5%, para un tamaño de muestra igual a 20, tomando 200 muestras de las poblaciones mencionadas y algunas otras. Como se refirió en la última sección del primer capítulo, compararon la efectividad de su prueba respecto a otros métodos ya conocidos, como la prueba χ^2 , la Kolmogorov-Smirnov, la Grañer-Von Mises y varias más, simulando para ello la potencia de cada una con el mismo procedimiento.

De forma similar, con el propósito de establecer un criterio de comparación entre la prueba original de Shapiro y Wilk y la modificación propuesta, se simuló la potencia de la primera conjuntamente a la de $W_0^{(n)}$, usando los coeficientes y percentiles correspondientes a cada tamaño de muestra, de acuerdo a las tablas que se encuentran en el artículo de los autores.

En la tabla II, se encuentran las potencias al 5% de W y $W_0^{(n)}$ simuladas y las respectivas derivadas por Shapiro y Wilk - para un tamaño de muestra igual a 20. Podemos observar que la potencia simulada de la estadística W , concuerda en buen grado con la derivada por sus autores, resultando en ambos casos sensible a la asimetría, a la dispersión por presencia de colas largas y, en algunos casos a la de colas cortas.

La potencia simulada de $W_0^{(n)}$ se encuentra siempre por debajo de la respectiva a W , lo cual era de esperarse debido a que ésta "usa" más información del comportamiento normal que $W_0^{(n)}$. Sin embargo, comparándola con los métodos b_2 , KS, CVM, WCVM, D y M, la potencia simulada de $W_0^{(n)}$ es mayor para casi todas las familias. En el caso de la χ^2 , $W_0^{(n)}$ detecta mejor la no normalidad para aquellas fami-

TABLA II. POTENCIAS SIMULADAS PARA UNA PRUEBA DE TAMAÑO 5% PARA $n = 20$

$W_0^{(n)}$ - Prueba Propuesta

W_1 - Prueba de Shapiro-Wilk (simulada)

W_2 - Prueba de Shapiro-Wilk (simulada mejores)

χ^2 - Prueba de la Ji-cuadrada

l_{b1} - Prueba del 3er momento estandarizado

b_2 - Prueba del 4to momento estandarizado

KS - Prueba de Kolmogorov-Smirnov

CVM - Prueba de Gómer-Von Mises

NCVM - Prueba de Gómer-Von Mises

ponderada por $F/(1-F)$ (función)

D - Prueba de Durbin

M - Prueba de David (rango/ desv. estandar)

	$W_0^{(n)}$	W_1	W_2	χ^2	l_{b1}	b_2	KS	CVM	NCVM	D	M
$\chi^2(1)$.88	.98	.98	.94	.89	.53	.44	.44	.54	.87	.10
$\chi^2(2)$.59	.80	.84	.33	.74	.34	.29	.23	.27	.42	.08
$\chi^2(4)$.33	.54	.50	.13	.49	.29	.18	.13	.16	.15	.06
$\chi^2(6)$.16	.24	.29	.07	.29	.19	.11	.10	.11	.07	.06
Lognor.	.81	.94	.93	.95	.89	.58	.44	.48	.62	.82	.06
Pois(1)	.60	.99	.99	1.0	.26	.11	.55	.22	.31	1.0	.35
Bin(4, .5)	.33	.75	.71	1.0	.02	.03	.38	.15	.17	1.0	.20

las que se asemejan mucho a la normal, mientras que para aquellas que son muy distintas, como la binomial y Poisson simuladas, es mucho más efectiva la prueba χ^2 . Una situación contraria se presenta con el método $\sqrt{|b|}$, el cual tiene potencias más altas que $W_0^{(n)}$ para las familias parecidas a la normal y menores en las muy disimiles.

En la tabla III aparecen las potencias simuladas para $n=10, 40$ y 50 de $W_0^{(n)}$ y W , haciéndose evidente que, aunque sigue siendo superior la efectividad de W , va disminuyendo la diferencia entre los dos métodos conforme aumenta el tamaño de muestra n , manteniéndose ligeramente mayor para las familias: $\chi^2(4)$, $\chi^2(10)$ y $Bin(4, 1/2)$.

TABLA III. POTENCIAS SIMULADAS DE $W_0^{(n)}$ y W CON UN TAMAÑO DE PRUEBA DE 5%.

Tamaño de muestra	$n=10$		$n=40$		$n=50$	
	$W_0^{(n)}$	W	$W_0^{(n)}$	W	$W_0^{(n)}$	W
$N(0,1)$.06	.05	.04	.03	.03	.03
$Exp(10)$.37	.44	.86	.99	.91	.99
Lognor.	.55	.62	.99	1.0	.99	1.0
$\chi^2(1)$.58	.71	.98	1.0	.99	1.0
$\chi^2(2)$.37	.44	.85	.99	.91	1.0
$\chi^2(4)$.23	.24	.55	.89	.63	.95
$\chi^2(10)$.10	.10	.23	.50	.31	.37
$B(4, 1/2)$.25	.48	.50	1.0	.56	1.0
Poiss(1)	.46	.75	.91	1.0	.96	1.0

c) CONCLUSIONES.

48

La estadística W compara la configuración estadística de la muestra en objeto, con la configuración de una muestra normal, a través de los momentos de primer y segundo orden de las estadísticas de orden normales. Similantemente la estadística $W_U^{(n)}$ realiza tal comparación, usando tan sólo la información contenida en los momentos de primer orden de las estadísticas de orden, de una muestra normal de tamaño dos. Lo notable es que con tan poca información se haya obtenido una potencia que, aunque siempre es menor que la respectiva de W , no lo es terriblemente.

A la fecha, existen proyectos para mejorar tal situación, cambiando el kernel de $\hat{J}_U^{(n)}$ por otros que incorporen un conocimiento semejante al de W .

Así pues, la idea de modificar \hat{J}_L por un estimador que sea estadística- U , es la parte medular de la modificación propuesta, y como dijimos antes, si se explota adecuadamente, puede llevarnos al descubrimiento de una prueba con potencia - muy semejante a la ideada por Shapiro y Wilk, que aparte tenga todas las ventajas ya mencionadas de $W_U^{(n)}$.

APENDICE A.

Demostración de las expresiones:

$$(a) \underline{1}^{(n)'} \underline{V}^{(n)} \underline{M}^{(n)} = 0.$$

$$(b) \underline{V}^{(n)} \underline{1}^{(n)} = \underline{1}^{(n)}$$

Afirmación 1.

Sea X va continua cuya función de densidad $f_X(\cdot)$ es simétrica respecto a la recta $x = \mu$, entonces:

$$\forall i \in \{1, \dots, n\} \quad \forall x \in \mathbb{R} \quad f_{X_{(i)}}(\mu+x) = f_{X_{(n-i+1)}}(\mu-x)$$

dem

Recordemos que:

$$f_{X_{(i)}}(x) = B(i, n-i+1)^{-1} F_X^{i-1}(x) [1 - F_X(x)]^{n-i} f_X(x)$$

Ahora dado que $f_X(\cdot)$ es simétrica respecto a $x = \mu$, se tiene: $\forall x \in \mathbb{R} \quad F_X(\mu-x) = 1 - F_X(x+\mu)$

Por lo que:

$$\begin{aligned} f_{X_{(n-i+1)}}(\mu-x) &= B(n-i+1, n-(n-i+1)+1)^{-1} F_X^{n-i+1}(\mu-x) \cdot \\ &\quad [1 - F_X(\mu-x)]^{n-(n-i+1)} f_X(\mu-x) \\ &= B(n-i+1, i)^{-1} F_X^{n-i}(\mu-x) [1 - F_X(\mu-x)]^{i-1} f_X(\mu-x) \\ &= B(i, n-i+1)^{-1} [1 - F_X(\mu+x)]^{n-i} F_X(\mu+x)^{i-1} \cdot \\ &\quad f_X(\mu+x) = f_{X_{(i)}}(\mu+x) \quad \blacksquare \end{aligned}$$

Afirmación 2.

Sea X va continua cuya función de densidad $f_X(\cdot)$ es simétrica respecto a la recta $x=0$, con esperanza finita, entonces:

$$\forall i \in \{1, \dots, n\} \quad \mathbb{E}[X_{(i)}] = -\mathbb{E}[X_{(n-i+1)}] \quad 50$$

dem

Sea $i \in \{1, \dots, n\}$

Por la proposición 1.

$$\forall x \in \mathbb{R} \quad f_{X_{(n-i+1)}}(-x) = f_{X_{(i)}}(x)$$

$$\therefore \mathbb{E}[X_{(n-i+1)}] = \int_{-\infty}^{\infty} x f_{X_{(n-i+1)}}(x) dx$$

Haciendo $x = -y$

$$\begin{aligned} \mathbb{E}[X_{(n-i+1)}] &= \int_{\infty}^{-\infty} (-y) f_{X_{(n-i+1)}}(-y) (-dy) \\ &= - \int_{-\infty}^{\infty} y f_{X_{(n-i+1)}}(-y) dy \\ &= - \int_{-\infty}^{\infty} y f_{X_{(i)}}(y) dy \\ &= -\mathbb{E}[X_{(i)}] \end{aligned}$$

Afirmación 3.

Sea X una variable aleatoria continua cuya función de densidad sea simétrica respecto a la recta $x = \mu$, entonces:

$$\forall \substack{i, j \in \{1, \dots, n\} \\ i \leq j} \quad \forall \substack{x, y \in \mathbb{R} \\ y \leq x} \quad f_{X_{(n-j+1)}, X_{(n-i+1)}}(\mu-x, \mu-y) \stackrel{51}{=} f_{X_{(i)}, X_{(j)}}(\mu+y, \mu+x)$$

dem

Sean $i, j \in \{1, \dots, n\}$ con $i \leq j$

Recordamos que la función de densidad conjunta de $X_{(i)}$ y $X_{(j)}$ está dada por:

$$f_{X_{(i)}, X_{(j)}}(x, y) = \begin{cases} \frac{n!}{(i-1)!(j-i-1)!(n-j)!} F_X^{i-1}(x) f_X(x) [F_X(y) - F_X(x)]^{j-i-1} \\ \quad f_X(y) [1 - F_X(y)]^{n-j} & \text{para } x \leq y \\ 0 & \text{en otro caso} \end{cases}$$

Sean $x, y \in \mathbb{R}$ con $y \leq x$, entonces

$$\begin{aligned} f_{X_{(n-j+1)}, X_{(n-i+1)}}(\mu-x, \mu-y) &= \\ & \frac{n!}{(n-j+1-1)!(n-i+1-(n-j+1)-1)!(n-(n-i+1))!} \\ & \times F_X^{n-j+1}(\mu-x) f_X(\mu-x) [F_X(\mu-y) - F_X(\mu-x)]^{n-i+1-(n-j+1)-1} \\ & \times f_X(\mu-y) [1 - F_X(\mu-y)]^{n-(n-i+1)} \\ &= \frac{n!}{(n-j)!(j-i-1)!(i-1)!} F_X^{n-j}(\mu-x) f_X(\mu-x) \\ & \times [F_X(\mu-y) - F_X(\mu-x)]^{j-i-1} f_X(\mu-y) [1 - F_X(\mu-y)]^{i-1} \end{aligned}$$

Usando nuevamente que:

52

$$\forall x \in \mathbb{R} \quad F_X(\mu-x) = 1 - F_X(\mu+x) \quad \text{y} \quad f(\mu-x) = f(\mu+x)$$

se tiene:

$$\begin{aligned} f_{X_{(n-j+1)}, X_{(n-i+1)}}(\mu-x, \mu-y) &= \frac{n!}{(i-1)!(j-i-1)!(n-j)!} \\ &\cdot [1 - F_X(\mu+x)]^{n-j} f_X(\mu+x) [1 - F_X(\mu+y) - (1 - F_X(\mu+x))]^{j-i-1} \\ &\quad f_X(\mu+y) [1 - (1 - F_X(\mu+y))]^{i-1} \\ &= \frac{n!}{(i-1)!(j-i-1)!(n-j)!} [1 - F_X(\mu+x)]^{n-j} f_X(\mu+x) \\ &\quad \cdot [F_X(\mu+x) - F_X(\mu+y)]^{j-i-1} f_X(\mu+y) F_X^{i-1}(\mu+y) \\ &= f_{X_{(i)}, X_{(j)}}(\mu+x, \mu+y) \quad \blacksquare \end{aligned}$$

Afirmación cuatro.

Sea X una variable aleatoria continua cuya función de densidad sea simétrica respecto a $x=0$, con media y varianza finitas, entonces:

$$\forall \substack{i, j \in \{1, \dots, n\} \\ i < j} \quad \text{cov}(X_{(i)}, X_{(j)}) = \text{cov}(X_{(n-i+1)}, X_{(n-j+1)})$$

dem.

$$\text{Cov}(X_{(n-j+1)}, X_{(n-i+1)})$$



53

$$= \int_{-\infty}^{\infty} \int_{-\infty}^y (x - E[X_{(n-j+1)}]) (y - E[X_{(n-i+1)}]) f_{X_{(n-j+1)}, X_{(n-i+1)}}(x, y) dx dy$$

Haciendo el cambio de variables

$$x = -v$$

$$y = -w$$



$$\left| \det \frac{D(x, y)}{D(v, w)} \right| = \left| \det \begin{pmatrix} +0 & -1 \\ -1 & 0 \end{pmatrix} \right| = 1$$

Usando la afirmación 3

$$\text{Cov}(X_{(n-j+1)}, X_{(n-i+1)})$$

$$= \int_{-\infty}^{\infty} \int_{-\infty}^v (-v + E[X_{(j)}]) (-w + E[X_{(i)}]) f_{X_{(j)}, X_{(i)}}(-v, -w) dv dw$$

us ahora por la afirmación 4 con $\mu=0$, la integral anterior es igual a:

$$\int_{-\infty}^{\infty} \int_{-\infty}^v (v - E[X_{(j)}]) (w - E[X_{(i)}]) f_{X_{(j)}, X_{(i)}}(w, v) dw dv = \text{Cov}(X_{(j)}, X_{(i)}) \blacksquare$$

Afirmación 5.

Sea X una variable aleatoria continua con función de densidad $f_X(\cdot)$ continua y con media y varianzas finitas, entonces:

$$a) \sum_{i=1}^n \mathbb{E}(X_{(i)}) = n \mathbb{E}(X)$$

$$b) \sum_{i=1}^n \mathbb{E}(X_{(i)}^2) = n \mathbb{E}(X^2)$$

$$c) \sum_{i=1}^n \sum_{j=1}^n \mathbb{E}(X_{(i)} X_{(j)}) = n \mathbb{E}(X^2) + n(n-1) \mathbb{E}^2(X)$$

$$d) \sum_{i=1}^n \sum_{j=1}^n \text{Cov}(X_{(i)}, X_{(j)}) = n \text{Var}(X)$$

dem

Teniendo en cuenta que:

$$\forall k, m \in \mathbb{N} \quad \left(\sum_{i=1}^n X_{(i)}^k \right)^m = \left(\sum_{i=1}^n X_i^k \right)^m$$

demostramos para toda $k \in \mathbb{N}$ la siguiente expresión:

$$\mathbb{E} \left[\sum_{i=1}^n X_{(i)}^k \right] = \mathbb{E} \left[\sum_{i=1}^n X_i^k \right]$$

$$\therefore \sum_{i=1}^n \mathbb{E} [X_{(i)}^k] = \sum_{i=1}^n \mathbb{E} [X_i^k] = n \mathbb{E} [X^k]$$

Con $k=1$ se obtiene a) y con $k=2$ b).

De igual forma con $k=1$ y $m=2$

$$\mathbb{E} \left[\sum_{i=1}^n X_{(i)} \right]^2 = \mathbb{E} \left[\sum_{i=1}^n X_i \right]^2$$

$$\sum_{i=1}^n \sum_{j=1}^n \mathbb{E} [X_{(i)} X_{(j)}] = \sum_{i=1}^n \sum_{j=1}^n \mathbb{E} [X_i X_j]$$

5 El miembro derecho de esta igualdad a su vez es igual a:

55

$$\begin{aligned} & \sum_{\substack{i=1 \\ i \neq j}}^n \sum_{j=1}^n \mathbb{E}[X_i X_j] + \sum_{i=1}^n \mathbb{E}[X_i^2] \\ &= \sum_{\substack{i=1 \\ i \neq j}}^n \sum_{j=1}^n \mathbb{E}[X_i] \mathbb{E}[X_j] + n \mathbb{E}[X^2] \\ &= n(n-1) \mathbb{E}^2[X] + n \mathbb{E}[X^2] \end{aligned}$$

$$\therefore \sum_{i=1}^n \sum_{j=1}^n \mathbb{E}[X_{(i)} X_{(j)}] = n \mathbb{E}[X^2] + n(n-1) \mathbb{E}^2[X]$$

lo cual demuestra c)

Por último usando: a) y el mismo argumento:

$$\begin{aligned} & \sum_{i=1}^n (X_{(i)} - \mathbb{E}(X_{(i)})) \text{ es igual a} \\ & \sum_{i=1}^n (X_i - \mathbb{E}(X_i)) \end{aligned}$$

de donde:

$$\mathbb{E} \left[\left(\sum_{i=1}^n (X_{(i)} - \mathbb{E}(X_{(i)})) \right)^2 \right] = \mathbb{E} \left[\left(\sum_{i=1}^n (X_i - \mathbb{E}(X_i)) \right)^2 \right]$$

ie

$$\begin{aligned} & \mathbb{E} \left[\sum_{i=1}^n \sum_{j=1}^n (X_{(i)} - \mathbb{E}(X_{(i)})) (X_{(j)} - \mathbb{E}(X_{(j)})) \right] = \\ & \mathbb{E} \left[\sum_{i=1}^n \sum_{j=1}^n (X_i - \mathbb{E}(X_i)) (X_j - \mathbb{E}(X_j)) \right] \end{aligned}$$

$$e) \sum_{i=1}^n \sum_{j=1}^n \text{cov}(X_{(i)}, X_{(j)}) = \sum_{i=1}^n \sum_{j=1}^n \text{cov}(X_i, X_j) \quad 56$$

y dado que $\forall_{i, j \in \{1, \dots, n\}} (i \neq j \Rightarrow \text{cov}(X_i, X_j) = 0)$

$$\sum_{i=1}^n \sum_{j=1}^n \text{cov}(X_i, X_j) = \sum_{i=1}^n \text{Var}(X_i) \\ = n \text{Var}(X)$$

$$\therefore \sum_{i=1}^n \sum_{j=1}^n \text{cov}(X_{(i)}, X_{(j)}) = n \text{Var}(X)$$

por lo que d) ha quedado demostrado y con ello la proposición cinco. ■

Afirmación 6.

Sea X una variable aleatoria que se distribuye según una $N(0, 1)$, entonces:

$$V \underline{1} = \underline{1}$$

donde V es la matriz de varianzas y covarianzas de $X_{(1)}, \dots, X_{(n)}$, las n -estadísticas de orden, correspondientes a una muestra aleatoria X_1, \dots, X_n de la misma distribución.

dem.

Aplicárese en orden ascendente las afirmaciones 2, 4 y 5. ■

Afirmación 7.

Sea X una variable aleatoria que se distribuye

según una $N(0,1)$, entonces:

$$\underline{1}' V^{-1} \underline{m} = 0$$

donde V es la misma matriz definida en la afirmación anterior y \underline{m} es el vector de medias respectivo.

dem

Dado que la familia normal es simétrica respecto a la media, en este caso igual a cero; la función de densidad conjunta de $X(1), \dots, X(n)$ es la misma que la del vector $-X(n), -X(n-1), \dots, -X(2), -X(1)$, es decir

$$\forall (x_1, \dots, x_n) \in \mathbb{R}^n \quad f_{X(1), X(2), \dots, X(n)}(x_1, \dots, x_n) = f_{-X(n), -X(n-1), \dots, -X(2), -X(1)}(x_1, \dots, x_n)$$

Ahora tomando

$$J = \begin{pmatrix} 0 & 0 & \dots & 0 & 1 \\ 0 & 0 & \dots & 1 & 0 \\ \vdots & \vdots & & \vdots & \vdots \\ 0 & 1 & \dots & 0 & 0 \\ 1 & 0 & \dots & 0 & 0 \end{pmatrix}$$

se tiene

$$\underline{X}^* := \begin{pmatrix} -X(n) \\ -X(n-1) \\ \vdots \\ -X(2) \\ -X(1) \end{pmatrix} = -J \begin{pmatrix} X(1) \\ X(2) \\ \vdots \\ X(n-1) \\ X(n) \end{pmatrix} = -J \underline{X}$$

Dado que ambos vectores tienen la misma función de densidad, ambos tienen por tanto, igual vector de medias e idéntica matriz de varianzas y covarianzas. En notación matricial:

$$E[\underline{X}^*] = E[\underline{X}]$$

$$\text{ie } E[-J\underline{x}] = E[\underline{x}]$$

$$\text{ie } -J E[\underline{x}] = E[\underline{x}]$$

$$\text{ie } -J \underline{m} = \underline{m}$$

De igual forma:

$$\text{Var}(\underline{x}^*) = \text{Var}(\underline{x})$$

$$\text{ie } \text{Var}(-J\underline{x}) = \text{Var}(\underline{x})$$

$$\text{ie } (-J)' \text{Var}(\underline{x}) (-J) = \text{Var}(\underline{x})$$

Ahora por definición de la matriz J se tiene que:

$$J = J'$$

\therefore la última igualdad se transforma en:

$$J \text{Var}(\underline{x}) J = \text{Var}(\underline{x})$$

$$\text{ie } J V J = V$$

$$\therefore V^{-1} = (J V J)^{-1}$$

$$= J^{-1} V^{-1} J^{-1}$$

Nuevamente por definición de J

$$J^{-1} = J$$

$$\therefore V^{-1} = J V^{-1} J$$

De aquí y del resultado anterior

$$\begin{aligned} \underline{1}' V^{-1} \underline{m} &= \underline{1}' (J V^{-1} J) \underline{m} \\ &= \underline{1}' (J V^{-1} J) (-J \underline{m}) \\ &= -(\underline{1}' J) V^{-1} (J \cdot J) \underline{m} \end{aligned}$$

Pero, por definición de J :

59

$$\underline{J}^{-1} = \underline{J} \quad \text{y} \quad \underline{1}' \underline{J} = \underline{1}'$$

$$\therefore \underline{1}' \underline{V}^{-1} \underline{M} = -\underline{1}' \underline{V}^{-1} \underline{M}$$

$$\text{ie} \quad \underline{1}' \underline{V}^{-1} \underline{M} = 0$$

APENDICE B.

Demostración de la proposición:

$$\begin{aligned} & \mathbb{E} [k |X_1 - X_2| \mid X_{(1)}^{(n-1)}, \dots, X_{(n-1)}^{(n-1)}, X_n] \\ &= \mathbb{E} [k |X_1 - X_2| \mid X_{(1)}^{(n-1)}, \dots, X_{(n-1)}^{(n-1)}] \end{aligned}$$

debido a la independencia de

$$X_{(1)}^{(n-1)}, \dots, X_{(n-1)}^{(n-1)} \text{ y } X_n \text{ y entre } k |X_1 - X_2|, X_{(1)}^{(n-1)}, \dots, X_{(n-1)}^{(n-1)} \text{ y } X_n.$$

dem:

Denotamos por \mathcal{Q}_{n-1} a $X_{(1)}^{(n-1)}, \dots, X_{(n-1)}^{(n-1)}$. Como $\mathbb{E}[k |X_1 - X_2| \mid \mathcal{Q}_{n-1}]$ es $\sigma(\mathcal{Q}_{n-1})$ medible y $\sigma(\mathcal{Q}_{n-1}) \subset \sigma(\mathcal{Q}_{n-1}, X_n)$, también es $\sigma(\mathcal{Q}_{n-1}, X_n)$ medible, por lo que si demostramos que:

$$\forall B \in \sigma(\mathcal{Q}_{n-1}, X_n) \int_B \mathbb{E}[k |X_1 - X_2| \mid \mathcal{Q}_{n-1}] dP = \int_B k |X_1 - X_2| dP$$

por la unicidad de la esperanza condicional, tendríamos la igualdad deseada:

$$\mathbb{E} [k |X_1 - X_2| \mid \mathcal{Q}_{n-1}, X_n] = \mathbb{E} [k |X_1 - X_2| \mid \mathcal{Q}_{n-1}]$$

Sean pues, $U_1, U_2, \dots, U_{n-1}, V$ abiertos de \mathbb{R} , denotemos por A al conjunto:

$$A := (X_{(1)}^{(n-1)})^{-1}(U_1) \cap (X_{(2)}^{(n-1)})^{-1}(U_2) \dots \cap (X_{(n-1)}^{(n-1)})^{-1}(U_{n-1})$$

claramente:

$$A \in \sigma(\mathcal{Q}_{n-1}) \text{ y } A \cap X_n^{-1}(V) \in \sigma(\mathcal{Q}_{n-1}, X_n).$$

Sea $\{S_m = \sum_{l=1}^{r_m} a_{lm} \chi_{A_{lm}}\}_{m \in \mathbb{N}}$ una sucesión de funciones simples crecientes que convergen a $\mathbb{E}[k|X_1 - X_2| | \mathcal{Q}_{n-1}]$. Dado que \mathcal{Q}_{n-1} y X_n son independientes, también lo son $\mathbb{E}[k|X_1 - X_2| | \mathcal{Q}_{n-1}]$ y X_n , por lo que es posible tomar las A_{lm} s independientes de $X_n^{-1}(v)$, es:

$$\forall_{m \in \mathbb{N}} \quad \forall_{l \in \{1, \dots, r_m\}} \quad A_{lm} \text{ es independiente de } X_n^{-1}(v),$$

y dado que $A \in \mathcal{Q}_{n-1}$, tenemos que:

$$\forall_{m \in \mathbb{N}} \quad \forall_{l \in \{1, \dots, r_m\}} \quad A_{lm} \cap A \text{ es independiente de } X_n^{-1}(v).$$

Por tanto:

$$\begin{aligned} \forall_{m \in \mathbb{N}} \int_{A \cap X_n^{-1}(v)} S_m dP &= \sum_{l=1}^{r_m} a_{lm} P(A \cap X_n^{-1}(v) \cap A_{lm}) \\ &= P(X_n^{-1}(v)) \int_A S_m dP \end{aligned}$$

$$\begin{aligned} \int_{A \cap X_n^{-1}(v)} \mathbb{E}[k|X_1 - X_2| | \mathcal{Q}_{n-1}] dP &= \lim_{m \rightarrow \infty} \int_{A \cap X_n^{-1}(v)} S_m dP \\ &= P(X_n^{-1}(v)) \lim_{m \rightarrow \infty} \int_A S_m dP \\ &= P(X_n^{-1}(v)) \int_A \mathbb{E}[k|X_1 - X_2| | \mathcal{Q}_{n-1}] dP \end{aligned}$$

$$\text{es } \int_{A \cap X_n^{-1}(v)} \mathbb{E}[k|X_1 - X_2| | \mathcal{Q}_{n-1}] dP = P(X_n^{-1}(v)) \int_A \mathbb{E}[k|X_1 - X_2| | \mathcal{Q}_{n-1}] dP$$

Sea $\{t_m = \sum_{i=1}^{q_m} b_{im} \chi_{B_{im}}\}_{m \in \mathbb{N}}$ una sucesión de funciones simples crecientes, que converge a $k|x_1 - x_2|$. Ahora dado que $k|x_1 - x_2|$, \mathcal{O}_{n-1} es indep. de X_n , podemos tomar las B_{im} \rightarrow .

62

$\forall m \in \mathbb{N}$ $\forall \{i \in \{1, \dots, q_m\}\}$ $B_{im} \cap A$ es indep. de $X_n^{-1}(U)$

$$\begin{aligned} \forall m \in \mathbb{N} \int_{A \cap X_n^{-1}(U)} t_m dP &= \sum_{i=1}^{q_m} b_{im} P(A \cap X_n^{-1}(U) \cap B_{im}) \\ &= P(X_n^{-1}(U)) \int_A t_m dP \end{aligned}$$

$$\int_{A \cap X_n^{-1}(U)} k|x_1 - x_2| dP = \lim_{m \rightarrow \infty} \int_{A \cap X_n^{-1}(U)} t_m dP$$

$$= P(X_n^{-1}(U)) \int_A k|x_1 - x_2| dP$$

$$\int_{A \cap X_n^{-1}(U)} k|x_1 - x_2| dP = P(X_n^{-1}(U)) \int_A k|x_1 - x_2| dP$$

y como $A \in \sigma(\mathcal{O}_{n-1})$ $\int_A k|x_1 - x_2| dP = \int_A \mathbb{E}[k|x_1 - x_2| | \mathcal{O}_{n-1}] dP$

$$\int_{A \cap X_n^{-1}(U)} \mathbb{E}[k|x_1 - x_2| | \mathcal{O}_{n-1}] dP = P(X_n^{-1}(U)) \int_A \mathbb{E}[k|x_1 - x_2| | \mathcal{O}_{n-1}] dP$$

$$= P(X_n^{-1}(U)) \int_A k|x_1 - x_2| dP = \int_{A \cap X_n^{-1}(U)} k|x_1 - x_2| dP$$

Con lo cual, hemos demostrado que:

63

$$\begin{aligned}
 & \forall \\
 & U_1, \dots, U_{n-1}, V \\
 & \text{abiertos de } \mathbb{R} \\
 & \int \mathbb{E}[k|X_1 - X_2| \mid \mathcal{Q}_{n-1}] dP \\
 & (X_{(1)}^{n-1})^{-1}(U_1) \cap \dots \cap (X_{(n-1)}^{n-1})^{-1}(U_{n-1}) \cap X_n^{-1}(V) \\
 & = \int k|X_1 - X_2| dP \\
 & (X_{(1)}^{n-1})^{-1}(U_1) \cap \dots \cap (X_{(n-1)}^{n-1})^{-1}(U_{n-1}) \cap X_n^{-1}(V) \\
 & = \int \mathbb{E}[k|X_1 - X_2| \mid \mathcal{Q}_{n-1}, X_n] dP \\
 & (X_{(1)}^{n-1})^{-1}(U_1) \cap \dots \cap (X_{(n-1)}^{n-1})^{-1}(U_{n-1}) \cap X_n^{-1}(V)
 \end{aligned}$$

Con lo que ambas esperanzas condicionales poseen la misma integral sobre cualquier conjunto de la clase

$$\mathcal{C} = \left\{ (X_{(1)}^{n-1})^{-1}(U_1) \cap \dots \cap (X_{(n-1)}^{n-1})^{-1}(U_{n-1}) \cap X_n^{-1}(V) \mid U_1, \dots, U_{n-1}, V \text{ son abiertos de } \mathbb{R} \right\}$$

Y dado que tal clase es cerrada bajo intersecciones, por el teorema de extensión:

$$\forall \mathcal{B} \in \sigma(\mathcal{C}) \quad \int_{\mathcal{B}} \mathbb{E}[k|X_1 - X_2| \mid \mathcal{Q}_{n-1}] dP = \int_{\mathcal{B}} \mathbb{E}[k|X_1 - X_2| \mid \mathcal{Q}_{n-1}, X_n] dP$$

pero $\sigma(\mathcal{C}) = \sigma(\mathcal{Q}_{n-1}, X_n)$; lo cual demuestra nuestra afirmación:

$$\mathbb{E}[k|X_1 - X_2| \mid \mathcal{Q}_{n-1}] = \mathbb{E}[k|X_1 - X_2| \mid \mathcal{Q}_{n-1}, X_n]$$

c.d

APÉNDICE C.

64

De los programas principales de la teoría de Estadísticas - U de Hoeffding, usados en la determinación de las distribuciones asintóticas de $\hat{T}_U^{(n)}$ y $W_U^{(n)}$.

TEOREMA 7.1

Sea X_1, \dots, X_n muestra aleatoria de $F_X(\cdot)$.

Sean $\varphi^{(l)}(x_1, \dots, x_{m(l)})$ $l=1, \dots, g$, g funciones reales que no dependan de n , simétricas en sus $m(l) \leq n$ argumentos.

Sean $\forall \{l, \dots, g\}$ $U^{(l)} = \binom{n}{m(l)}^{-1} \sum' \varphi^{(l)}(X_{j_1}, \dots, X_{j_{m(l)}})$

donde \sum' es la suma sobre todas las permutaciones ordenadas del conjunto de índices $\{1, \dots, n\}$.

Si existen $\forall \{l, \dots, g\}$ $\mathbb{E}[\varphi^{(l)}(X_1, \dots, X_{m(l)})] = \theta^{(l)}$ y $\mathbb{E}[\varphi^{(l)}(X_1, \dots, X_{m(l)})]^2$

entonces:

la distribución conjunta de

$\sqrt{n} (U^{(1)} - \theta^{(1)}, U^{(2)} - \theta^{(2)}, \dots, U^{(g)} - \theta^{(g)})$ tiende, cuando $n \rightarrow \infty$, a una normal g -variada con media cero y matriz de varianzas y covarianzas:

$$V = (m(i)m(j) \zeta_{ij}^{(i,j)})_{i,j \in \{1, \dots, g\}}$$

donde

$$\zeta_{ij}^{(i,j)} = \mathbb{E}[(\varphi_i^{(i)}(X_i) - \theta^{(i)})(\varphi_j^{(j)}(X_j) - \theta^{(j)})]$$

con $\varphi_1^{(i)}(x_i) = \mathbb{E} \left[\varphi^{(i)}(x_1, x_2, \dots, x_{m(i)}) \right]$ 65

para $i \in \{1, \dots, g\}$.

Además, si el determinante de la matriz

$(\zeta_1^{(i,j)})_{i,j \in \{1, \dots, g\}}$ es positivo,

entonces la función de distribución límite es no-singular.

Nota: Para $g=1$, el teorema anterior nos indica, bajo ciertas condiciones, la distribución asintótica de una estadística-U.

TEOREMA 7.2

Bajo las mismas hipótesis del teorema 7.1,

y si $\forall i, j \in \{1, \dots, g\} \quad \zeta_1^{(i,j)} > 0$ entonces

la distribución conjunta de:

$$\left(\frac{U^{(1)} - \theta^{(1)}}{\sqrt{\text{Var}(U^{(1)})}}, \dots, \frac{U^{(g)} - \theta^{(g)}}{\sqrt{\text{Var}(U^{(g)})}} \right)$$

tendrá, cuando $n \rightarrow \infty$, a una normal g -variada con media cero y matriz de varianzas y

covarianzas: $(\rho^{(i,j)})_{i,j \in \{1, \dots, g\}}$ donde

$$\begin{aligned} \rho^{(i,j)} &= \lim_{n \rightarrow \infty} \frac{\text{cov}(U^{(i)}, U^{(j)})}{(\text{Var}(U^{(i)}) \text{Var}(U^{(j)}))^{1/2}} \\ &= \frac{\zeta_1^{(i,j)}}{(\zeta_1^{(i)} \zeta_1^{(j)})^{1/2}} \quad i, j \in \{1, \dots, g\} \end{aligned}$$

Este teorema es un corolario del anterior

Sea $\forall i \in \{1, \dots, g\}$ $\{Y_n^{(i)}\}_{n=1}^{\infty}$ una sucesión de variables aleatorias tal que:

$$\lim_{n \rightarrow \infty} E[Y_n^{(i)}]^2 = 0$$

Sea $\forall i \in \{1, \dots, g\}$ $U^{(i)'} = U^{(i)} + \frac{Y_n^{(i)}}{\sqrt{n}}$

donde $U^{(i)}$ está dada por las mismas condiciones del teorema 7.1, entonces la función de distribución conjunta de

$$\sqrt{n} (U^{(1)'} - \theta^{(1)}, \dots, U^{(g)'} - \theta^{(g)})$$

tiende, cuando $n \rightarrow \infty$, a una normal g -variada con media cero y matriz de varianzas y covarianzas $(m^{(i)}m^{(j)} \sum_{i,j} \gamma_{ij})_{ij}$

TEOREMA 7.5.

Sean $U^{(i)'} \quad i=1, \dots, g$ como en el teorema anterior. Sea $h(y_1, \dots, y_g) \in C^2(B_\epsilon(\underline{\theta}))$ donde $\epsilon > 0$ y $\underline{\theta} = (\theta^{(1)}, \dots, \theta^{(g)})$, entonces si h no involucra a n , la distribución de:

$$Z_n = \sqrt{n} (h(U^{(1)'}, \dots, U^{(g)'}) - h(\underline{\theta}))$$

tiende asintóticamente a una distribución normal con media cero y varianzas:

$$\sum_{i=1}^g \sum_{j=1}^g m^{(i)}m^{(j)} h_{y_i}(\underline{\theta}) h_{y_j}(\underline{\theta}) \gamma_{ij}$$

De los cálculos necesarios para la determinación de las distribuciones asintóticas de $\hat{\sigma}_U^{(n)}$ y $W_U^{(n)}$.

$$1) \mathbb{E}[\hat{\sigma}_1^{(2)}(X)] = \left(\frac{\pi}{12} + \frac{\sqrt{3}}{2} \right) \sigma^2$$

Como $\Phi(x_1, x_2) = k|x_1 - x_2|$ con $k = \sqrt{\pi}/2$

$$\begin{aligned} \Phi_1^{(1)}(x_1) &= \mathbb{E}[\Phi(x_1, x_2)] = \mathbb{E}[k|x_1 - x_2|] \\ &= \int_{-\infty}^{\infty} k|x_1 - x_2| \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2\sigma^2}(x_2 - \mu)^2} dx_2 \end{aligned}$$

Ahora tomando $z = \frac{x_2 - \mu}{\sigma}$

$$\Phi_1(x_1) = \int_{-\infty}^{\infty} \frac{k}{\sqrt{2\pi}} |x_1 - \sigma z - \mu| e^{-\frac{1}{2}z^2} dz$$

$$= \frac{k}{\sqrt{2\pi}} \int_{-\infty}^{\frac{x_1 - \mu}{\sigma}} (x_1 - \sigma z - \mu) e^{-\frac{1}{2}z^2} dz + \frac{k}{\sqrt{2\pi}} \int_{\frac{x_1 - \mu}{\sigma}}^{\infty} (\sigma z + \mu - x_1) e^{-\frac{1}{2}z^2} dz$$

$$= \frac{k}{\sqrt{2\pi}} (x_1 - \mu) \left[\int_{-\infty}^{\frac{x_1 - \mu}{\sigma}} e^{-\frac{1}{2}z^2} dz - \int_{\frac{x_1 - \mu}{\sigma}}^{\infty} e^{-\frac{1}{2}z^2} dz \right]$$

$$- \frac{\sigma k}{\sqrt{2\pi}} \left[-e^{-\frac{1}{2}z^2} \Big|_{-\infty}^{\frac{x_1 - \mu}{\sigma}} + e^{-\frac{1}{2}z^2} \Big|_{\frac{x_1 - \mu}{\sigma}}^{\infty} \right]$$

$$= k(x_1 - \mu) \left[\int_{-\frac{(x_1 - \mu)}{\sigma}}^{\infty} e^{-\frac{1}{2}z^2} dz - \int_{\frac{(x_1 - \mu)}{\sigma}}^{\infty} e^{-\frac{1}{2}z^2} dz \right]$$

- continúa en la página siguiente.

$$\begin{aligned}
 & -\frac{\sigma k}{\sqrt{2\pi}} \left[-e^{-\frac{1}{2}\left(\frac{x_1-\mu}{\sigma}\right)^2} - e^{-\frac{1}{2}\left(\frac{x_1-\mu}{\sigma}\right)^2} \right] \\
 & = \frac{k(x_1-\mu)}{\sqrt{2\pi}} \int_{-\left(\frac{x_1-\mu}{\sigma}\right)}^{\left(\frac{x_1-\mu}{\sigma}\right)} e^{-\frac{1}{2}z^2} dz + \frac{2\sigma k}{\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x_1-\mu}{\sigma}\right)^2}
 \end{aligned}$$

$$\begin{aligned}
 \therefore E[\hat{Q}_1^2(x_1)] & = \\
 & \int_{-\infty}^{\infty} \left(\int_{-\infty}^{\infty} k|x_1-x_2| \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2\sigma^2}(x_2-\mu)^2} dx_2 \right)^2 \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2\sigma^2}(x_1-\mu)^2} dx_1 \\
 & = \int_{-\infty}^{\infty} \left[\frac{2\sigma k}{\sqrt{2\pi}} \left(\left(\frac{x_1-\mu}{\sigma}\right) \int_0^{\left(\frac{x_1-\mu}{\sigma}\right)} e^{-\frac{1}{2}z^2} dz + e^{-\frac{1}{2}\left(\frac{x_1-\mu}{\sigma}\right)^2} \right) \right]^2 \\
 & \quad \times \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x_1-\mu}{\sigma}\right)^2} dx_1
 \end{aligned}$$

Tomando $\psi = \frac{x_1-\mu}{\sigma}$

$$\begin{aligned}
 E[\hat{Q}_1^2(x_1)] & = \\
 & \int_{-\infty}^{\infty} \left[\frac{2\sigma k}{\sqrt{2\pi}} \left(\psi \int_0^{\psi} e^{-\frac{1}{2}z^2} dz + e^{-\frac{1}{2}\psi^2} \right) \right]^2 \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\psi^2} \sigma d\psi \\
 & = \frac{4\sigma^2 k^2}{(2\pi)^{3/2}} \int_{-\infty}^{\infty} \left(\psi \int_0^{\psi} e^{-\frac{1}{2}z^2} dz + e^{-\frac{1}{2}\psi^2} \right)^2 e^{-\frac{1}{2}\psi^2} d\psi
 \end{aligned}$$

Denotamos por I_{HT} a la integral anterior.

Sea
$$h(\psi) = \int_0^\psi e^{-\frac{1}{2}z^2} dz \quad \therefore h'(\psi) = e^{-\frac{1}{2}\psi^2}$$

Con esta notación I_{HT} queda como:

$$\begin{aligned} I_{HT} &= \int_{-\infty}^{\infty} (\psi h(\psi) + h'(\psi))^2 h'(\psi) d\psi \\ &= \int_{-\infty}^{\infty} (\psi^2 h(\psi)^2 h'(\psi) + 2\psi h(\psi) h'(\psi)^2 + h'(\psi)^3) d\psi \end{aligned}$$

Sean
$$(A) = \int_{-\infty}^{\infty} \psi^2 h(\psi)^2 h'(\psi) d\psi$$

$$(B) = \int_{-\infty}^{\infty} 2\psi h(\psi) h'(\psi)^2 d\psi$$

$$(C) = \int_{-\infty}^{\infty} h'(\psi)^3 d\psi$$

$$(A) = \int_{-\infty}^{\infty} \psi^2 h(\psi)^2 h'(\psi) d\psi$$

$$\begin{aligned} dv &= \psi^2 h'(\psi) & \mu &= h^2(\psi) \\ v &= -\psi h'(\psi) + h(\psi) & d\mu &= 2h(\psi) h'(\psi) \end{aligned}$$

$$\begin{aligned} (A) &= (-\psi h'(\psi) + h(\psi)) h^2(\psi) \Big|_{-\infty}^{\infty} \\ &\quad - \int_{-\infty}^{\infty} (-\psi h'(\psi) + h(\psi)) 2h(\psi) h'(\psi) d\psi \end{aligned}$$

$$\text{Sean } (a) = (-\psi h'(\psi) + h(\psi)) h^2(\psi) \Big|_{-\infty}^{\infty}$$

70

$$(b) = 2 \int_{-\infty}^{\infty} \psi h(\psi) h'(\psi)^2 d\psi$$

$$\text{y } (c) = -2 \int_{-\infty}^{\infty} h(\psi)^2 h'(\psi) d\psi$$

$$\text{entonces } (A) = (a) + (b) + (c)$$

$$\text{Ahora } (a) = -\psi h'(\psi) h^2(\psi) \Big|_{-\infty}^{\infty} + h^3(\psi) \Big|_{-\infty}^{\infty} = h^3(\infty) - h^3(-\infty)$$

$$= \left(\int_0^{\infty} e^{-\frac{1}{2} z^2} dz \right)^3 - \left(\int_0^{-\infty} e^{-\frac{1}{2} z^2} dz \right)^3$$

$$= 2 \left(\frac{\sqrt{2\pi}}{2} \right)^3 = \frac{(2\pi)^{3/2}}{4}$$

$$(b) = 2 \int_{-\infty}^{\infty} \psi h(\psi) h'(\psi)^2 d\psi$$

$$\begin{aligned} dv &= \psi h'(\psi)^2 & \mu &= h(\psi) \\ v &= -\frac{1}{2} h'(\psi)^2 & d\mu &= h'(\psi) \end{aligned}$$

$$\therefore (b) = 2 h(\psi) \left(-\frac{1}{2} h'(\psi)^2 \right) \Big|_{-\infty}^{\infty} - 2 \int_{-\infty}^{\infty} \left(-\frac{1}{2} \right) h'(\psi)^3 d\psi$$

$$\text{ie } (b) = \int_{-\infty}^{\infty} h'(\psi)^3 d\psi = \int_{-\infty}^{\infty} (e^{-\frac{1}{2}\psi^2})^3 d\psi$$

$$= \int_{-\infty}^{\infty} e^{-\frac{3}{2}\psi^2} d\psi = \frac{\sqrt{2\pi}}{\sqrt{3}}$$

71

$$(c) = -2 \int_{-\infty}^{\infty} h(\psi)^2 h'(\psi) d\psi = -\frac{2}{3} h(\psi)^3 \Big|_{-\infty}^{\infty}$$

$$= -\frac{2}{3} [h^3(\infty) - h^3(-\infty)] = -\frac{2}{3} \left[\frac{(2\pi)^{3/2}}{4} \right]$$

$$= -\frac{(2\pi)^{3/2}}{6}$$

$$\therefore (A) = \frac{(2\pi)^{3/2}}{4} + \frac{(2\pi)^{1/2}}{3\sqrt{2}} - \frac{(2\pi)^{3/2}}{6}$$

$$= \frac{(2\pi)^{3/2}}{12} + \frac{(2\pi)^{1/2}}{3\sqrt{2}}$$

Observando que $(B) = (b)$, tenemos:

$$(B) = \frac{(2\pi)^{1/2}}{3\sqrt{2}}$$

De igual forma $(C) = (b)$

$$\therefore (C) = \frac{(2\pi)^{1/2}}{3\sqrt{2}}$$

por lo que, finalmente:

$$I_{\pi} = A + B + C = \frac{(2\pi)^{3/2}}{12} + \frac{(2\pi)^{1/2}}{3\sqrt{2}} + \frac{(2\pi)^{1/2}}{3\sqrt{2}} + \frac{(2\pi)^{1/2}}{3\sqrt{2}}$$

con $\psi = \frac{x_2 - \mu}{\sigma}$, per lo que:

72

$$\begin{aligned} \zeta_1^{(1,2)} &= \int_{-\infty}^{\infty} \frac{2\sigma k}{2\sqrt{2\pi}} \left[\psi \int_0^{\psi} e^{-\frac{1}{2}t^2} dt + e^{-\frac{1}{2}\psi^2} \right] \\ &\quad \times \left[\sigma^2 \psi^2 + \sigma^2 \right] \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}\psi^2} d\psi - \sigma^3 \\ &= \frac{\sigma^3 k}{(\sqrt{2\pi})^2} \int_{-\infty}^{\infty} (\psi h(\psi) + h'(\psi)) (\psi^2 + 1) h'(\psi) d\psi - \sigma^3 \end{aligned}$$

con $h(\psi) = \int_0^{\psi} e^{-\frac{1}{2}t^2} dt$.

Sean:

$$(A) = \int_{-\infty}^{\infty} \psi^3 h(\psi) h'(\psi) d\psi$$

$$(B) = \int_{-\infty}^{\infty} \psi h(\psi) h'(\psi) d\psi$$

$$(C) = \int_{-\infty}^{\infty} \psi^2 h'(\psi)^2 d\psi$$

$$\text{y } (D) = \int_{-\infty}^{\infty} h'(\psi)^2 d\psi$$

ie

$$\zeta_1^{(1,2)} = \frac{\sigma^3 k}{2\pi} \left((A) + (B) + (C) + (D) \right) - \sigma^3$$

$$(A) = \int_{-\infty}^{\infty} \psi^3 h(\psi) h'(\psi) d\psi$$

$$dv = \psi^3 h'(\psi)$$

$$v = -h'(\psi)(\psi^2 + 2)$$

$$u = h(\psi)$$

$$du = h'(\psi)$$

73

$$(A) = -h'(\psi)(\psi^2 + 2)h(\psi) \Big|_{-\infty}^{\infty} - \int_{-\infty}^{\infty} -h'(\psi)^2(\psi^2 + 2) d\psi$$

$$= \int_{-\infty}^{\infty} h'(\psi)^2(\psi^2 + 2) d\psi$$

$$= \int_{-\infty}^{\infty} \psi^2 h'(\psi)^2 d\psi + \int_{-\infty}^{\infty} 2h'(\psi)^2 d\psi$$

$$= \frac{1}{2} \psi h'(\psi)^2 \Big|_{-\infty}^{\infty} - \int_{-\infty}^{\infty} \frac{1}{2} h'(\psi)^2 d\psi + 2\pi^{1/2}$$

$$= \frac{1}{2} \int_{-\infty}^{\infty} h'(\psi)^2 d\psi + 2\pi^{1/2} = \frac{\pi^{1/2}}{2} + 2\pi^{1/2}$$

$$(B) = \int_{-\infty}^{\infty} \psi h(\psi) h'(\psi) d\psi$$

$$dv = \psi h'(\psi)$$

$$v = -h'(\psi)$$

$$u = h(\psi)$$

$$du = h'(\psi)$$

$$(B) = -h'(\psi)h(\psi) \Big|_{-\infty}^{\infty} - \int_{-\infty}^{\infty} -h'(\psi)h'(\psi) d\psi$$

$$= \int_{-\infty}^{\infty} h'(\psi)^2 d\psi = \pi^{1/2}$$

$$(C) = \int_{-\infty}^{\infty} \psi^2 h'(\psi)^2 d\psi = \frac{\pi^{1/2}}{2}$$

$$(D) = \int_{-\infty}^{\infty} h'(\psi)^2 d\psi = \pi^{1/2}$$

$$\text{ie } I_{2T} = \frac{(2\pi)^{3/2}}{12} + (6\pi)^{1/2}$$

74

$$\begin{aligned} \therefore \mathbb{E}[\Phi^2(x_1)] &= \frac{4\sigma^2 k^2}{(2\pi)^{3/2}} I_{2T} \\ &= \frac{4\sigma^2 k^2}{(2\pi)^{3/2}} \left[\frac{(2\pi)^{3/2}}{12} + (6\pi)^{1/2} \right] \end{aligned}$$

y como $k = \sqrt{\pi}/2$, entonces:

$$\begin{aligned} \mathbb{E}[\overset{ii}{\Phi}^2(x_1)] &= \frac{\pi\sigma^2}{(2\pi)^{3/2}} \left[\frac{(2\pi)^{3/2}}{12} + (6\pi)^{1/2} \right] \\ &= \left(\frac{\pi}{12} + \frac{\sqrt{3}}{2} \right) \sigma^2 \\ &\approx (1.1278247416) \sigma^2 \end{aligned}$$

$$2) \mathbb{E}[\overset{iii}{\Phi}_2^2(x_1, x_2)] = \frac{\pi}{2} \sigma^2$$

$$\overset{iii}{\Phi}_2(x_1, x_2) = k|x_1 - x_2|$$

$$\begin{aligned} \therefore \mathbb{E}[\overset{iii}{\Phi}_2^2(x_1, x_2)] &= \mathbb{E}[k^2(x_1 - x_2)^2] \\ &= k^2 \mathbb{E}[(x_1 - x_2)^2] \end{aligned}$$

Ahora como $x_1, x_2 \sim N(\mu, \sigma^2)$

$$x_1 - x_2 \sim N(0, 2\sigma^2)$$

$$\therefore \mathbb{E}(x_1 - x_2) = 0 \text{ y } \text{Var}(x_1 - x_2) = 2\sigma^2$$

$$\text{ie } 2\sigma^2 = \mathbb{E}[(x_1 - x_2)^2] + \mathbb{E}^2(x_1 - x_2)$$

$$\therefore \mathbb{E}[(x_1 - x_2)^2] = 2\sigma^2$$

$$\begin{aligned} \therefore \mathbb{E}[\overset{iii}{\Phi}_2^2(x_1, x_2)] &= k^2 \cdot 2\sigma^2 \\ &= \frac{\pi}{2} \sigma^2 \end{aligned}$$

$$3) \zeta_1^{(1,2)} = \frac{1}{4} \sigma^3$$

75

Por definición $\zeta_1^{(1,2)} = \mathbb{E} [\psi_1^{(1)}(x_1) \psi_1^{(2)}(x_1)]$

donde $\psi_1^{(1)}(x_1) = \mathbb{E} [\Phi^{(1)}(x_1, x_2) - \sigma]$

y $\psi_1^{(2)}(x_1) = \mathbb{E} [\Phi^{(2)}(x_1, x_2) - \sigma^2]$

Ahora $\Phi^{(1)}(x_1, x_2) = k |x_1 - x_2|$

$$\therefore \psi_1^{(1)}(x_1) = \int_{-\infty}^{\infty} k |x_1 - x_2| \frac{1}{\sigma \sqrt{2\pi}} e^{-\frac{1}{2} \left(\frac{x_2 - \mu}{\sigma} \right)^2} dx_2 - \sigma$$

De igual forma: $\Phi^{(2)}(x_1, x_2) = \frac{(x_1 - x_2)^2}{2}$

$$\begin{aligned} \therefore \psi_1^{(2)}(x_1) &= \frac{1}{2} \mathbb{E} [x_1^2 - 2x_1x_2 + x_2^2] - \sigma^2 \\ &= \frac{1}{2} [(x_1 - \mu)^2 + \sigma^2] - \sigma^2 \end{aligned}$$

De donde:

$$\begin{aligned} \zeta_1^{(1,2)} &= \int_{-\infty}^{\infty} \left(\int_{-\infty}^{\infty} k |x_1 - x_2| \frac{1}{\sigma \sqrt{2\pi}} e^{-\frac{1}{2} \left(\frac{x_2 - \mu}{\sigma} \right)^2} dx_2 \right) \\ &\quad \times \frac{1}{2} [(x_1 - \mu)^2 + \sigma^2] \frac{1}{\sigma \sqrt{2\pi}} e^{-\frac{1}{2} \left(\frac{x_1 - \mu}{\sigma} \right)^2} dx_1 - \sigma^3 \end{aligned}$$

Pero por la sección 1) de este apéndice

$$\int_{-\infty}^{\infty} k |x_1 - x_2| \frac{1}{\sigma \sqrt{2\pi}} e^{-\frac{1}{2} \left(\frac{x_2 - \mu}{\sigma} \right)^2} dx_2 =$$

$$\frac{2\sigma k}{\sqrt{2\pi}} \left[\psi \int_0^\psi e^{-\frac{1}{2} z^2} dz + e^{-\frac{1}{2} \psi^2} \right]$$

$$\begin{aligned} \therefore \zeta_1^{(1,2)} &= \frac{\sigma^3 k}{2\pi} \left[\frac{\pi^{1/2}}{2} + 2\pi^{1/2} + \pi^{1/2} + \frac{\pi^{1/2}}{2} + \pi^{1/2} \right] - \sigma^3 \\ &= \frac{\sigma^3 k}{2\pi} \cdot 5\pi^{1/2} - \sigma^3 \quad \text{como } k = \frac{\pi^{1/2}}{2} \\ &= \frac{5}{4} \sigma^3 - \sigma^3 = \frac{1}{4} \sigma^3 \end{aligned}$$

4) $\zeta_1^{(2,2)} = \frac{1}{2} \sigma^4$

Por definición $\zeta_1^{(2,2)} = \mathbb{E} [\varphi_1^{(2)}(X_1)]^2 - (\sigma^2)^2$
 donde $\varphi_1^{(2)}(x_1) = \mathbb{E} [\varphi^{(2)}(x_1, X_2)]$
 $= \mathbb{E} [\frac{(x_1 - X_2)^2}{2}]$

Ahora $\mathbb{E} [\frac{1}{2} (x_1 - X_2)^2] = \mathbb{E} [\frac{1}{2} (x_1^2 - 2x_1X_2 + X_2^2)]$
 $= \frac{1}{2} (x_1^2 - 2x_1\mu + \mu^2 + \sigma^2)$
 $= \frac{1}{2} ((x_1 - \mu)^2 + \sigma^2)$
 $= \frac{1}{2} (\sigma^2 (\frac{x_1 - \mu}{\sigma})^2 + \sigma^2)$
 $= \frac{\sigma^2}{2} ((\frac{x_1 - \mu}{\sigma})^2 + 1)$

$\therefore \mathbb{E} [\varphi_1^{(2)}(X_1)]^2 = \mathbb{E} [\frac{\sigma^2}{2} ((\frac{X_1 - \mu}{\sigma})^2 + 1)]^2$
 $= \frac{\sigma^4}{4} \mathbb{E} [(\frac{X_1 - \mu}{\sigma})^2 + 1]^2$

Como $X_1 \sim N(\mu, \sigma^2)$ entonces $\frac{X_1 - \mu}{\sigma} \sim N(0, 1)$

y $\therefore (\frac{X_1 - \mu}{\sigma})^2 = Z^2 \sim \chi^2(1)$

$$\therefore \mathbb{E}[z^2] = 1 \quad \text{y} \quad \text{Var}(z^2) = 2$$

$$\begin{aligned} \therefore \mathbb{E}[(z^2)^2] &= \text{Var}(z^2) + \mathbb{E}^2(z^2) \\ &= 2 + 1 = 3 \end{aligned}$$

$$\text{ie } \mathbb{E}\left[\left(\frac{X_1+1}{\sigma}\right)^2\right]^2 = 3$$

$$\begin{aligned} \therefore \mathbb{E}\left[\varphi_1^{(2)}(X_1)\right]^2 &= \frac{\sigma^4}{4} \mathbb{E}\left[(z^2+1)^2\right] \\ &= \frac{\sigma^4}{4} \mathbb{E}\left[(z^2)^2 + 2z^2 + 1\right] \\ &= \frac{\sigma^4}{4} [3 + 2 + 1] = \frac{3}{2}\sigma^4 \end{aligned}$$

$$\therefore \zeta_1^{(2,2)} = \frac{3}{2}\sigma^4 - \sigma^4 = \frac{1}{2}\sigma^4$$

$$5) \zeta_2^{(2,2)} = 2\sigma^4$$

Por definición $\zeta_2^{(2,2)} = \mathbb{E}\left[\varphi_2^{(2)}(X_1, X_2)\right]^2 - (\sigma^2)^2$

donde $\varphi_2^{(2)}(X_1, X_2) = \frac{(X_1 - X_2)^2}{2}$

$$\therefore \mathbb{E}\left[\varphi_2^{(2)}(X_1, X_2)\right]^2 = \mathbb{E}\left[\frac{(X_1 - X_2)^4}{4}\right]$$

Dado que $X_1, X_2 \sim N(\mu, \sigma^2)$
 $X_1 - X_2 \sim N(0, 2\sigma^2)$

$$\therefore \frac{X_1 - X_2}{\sqrt{2}\sigma} \sim N(0, 1)$$

$$\therefore \left(\frac{X_1 - X_2}{\sqrt{2}\sigma}\right)^2 = \frac{(X_1 - X_2)^2}{2\sigma^2} \sim \chi^2(1)$$

$$\therefore \mathbb{E} \left[\frac{(X_1 - X_2)^2}{2\sigma^2} \right] = 1 \quad \text{y} \quad \text{Var} \left[\frac{(X_1 - X_2)^2}{2\sigma^2} \right] = 2 \quad 78$$

$$\therefore \mathbb{E} \left[\frac{(X_1 - X_2)^2}{2\sigma^2} \right]^2 = 2 + 1 = 3$$

$$\text{ie} \quad \mathbb{E} \left[\frac{(X_1 - X_2)^4}{4} \right] = 3\sigma^4$$

$$\therefore \begin{cases} (2,2) \end{cases} = 3\sigma^4 - \sigma^4 = 2\sigma^4$$

$$6) \sqrt{n} (W_0^{(n)} - 1) \xrightarrow[n \rightarrow \infty]{D} N(0, \lambda^2)$$

$$\text{donde } \lambda^2 = 16 \left(\frac{\pi}{12} + \frac{\sqrt{3}}{2} - 1 \right) - 2$$

$$\approx .045196669$$

dem.

Se aplica el teorema 7.5 del apéndice anterior, tomando:

$$U(1)' = U(1) = \hat{\sigma}_0^{(n)} \quad m(1) = 2$$

$$U(2)' = U(2) = \sigma^2 \quad m(2) = 2$$

$$\text{y } h(y_1, y_2) = \frac{y_1^2}{4_2} \quad \text{Veamos:}$$

$$\text{Como } h_{y_1} = \frac{2y_1}{4_2}, \quad h_{y_2} = \frac{-y_1^2}{4_2^2}, \quad h_{y_1 y_2} = -\frac{2y_1}{4_2^2},$$

$$h_{y_2 y_1} = \frac{-2y_1}{4_2^2}, \quad h_{y_1 y_1} = \frac{2}{4_2}, \quad h_{y_2 y_2} = \frac{2y_1^2}{4_2^3}$$

y h son continuas en $\mathcal{Q} = (\sigma, \sigma^2)$, la variable aleatoria:

$$\sqrt{n} (h(\hat{\sigma}_0^{(n)}, \sigma^2) - h(\sigma, \sigma^2)) \text{ tiene por distri-}$$

bución asintótica a una $N(0, \lambda^2)$, donde λ^2 es igual a:

79

$$\lambda^2 = m(1)^2 h_{y_1}^2(\sigma, \sigma^2) \zeta_1^{(1,1)} + 2 m(1) m(2) h_{y_1}(\sigma, \sigma^2) h_{y_2}(\sigma, \sigma^2) \zeta_1^{(1,2)} + (m(2))^2 h_{y_2}^2(\sigma, \sigma^2) \zeta_1^{(2,2)}$$

Ahora, por las secciones anteriores de este apéndice

$$\zeta_1^{(1,1)} = \left(\frac{\pi}{12} + \frac{\sqrt{3}}{2} - 1 \right) \sigma^2$$

$$\zeta_1^{(1,2)} = \frac{1}{4} \sigma^3 \quad \text{y}$$

$$\zeta_1^{(2,2)} = \frac{1}{2} \sigma^4$$

$$\begin{aligned} \therefore \lambda^2 &= 4 \left(\frac{2}{\sigma} \right)^2 \left(\frac{\pi}{12} + \frac{\sqrt{3}}{2} - 1 \right) \sigma^2 \\ &+ 8 \left(\frac{2}{\sigma} \right) \left(-\frac{1}{\sigma^2} \right) \frac{1}{4} \sigma^3 \\ &+ 4 \left(-\frac{1}{\sigma^2} \right)^2 \frac{1}{2} \sigma^4 \\ &= 16 \left(\frac{\pi}{12} + \frac{\sqrt{3}}{2} - 1 \right) - 4 + 2 \\ &= 16 \left(\frac{\pi}{12} + \frac{\sqrt{3}}{2} - 1 \right) - 2 \end{aligned}$$

ya que $h_{y_1}(\sigma, \sigma^2) = \frac{2\sigma}{\sigma^2} = \frac{2}{\sigma}$

y $h_{y_2}(\sigma, \sigma^2) = \frac{-\sigma^2}{(\sigma^2)^2} = -\frac{1}{\sigma^2}$

- [1]. SHAPIRO S.S. and WILK M.B. (1965)
"An analysis of variance test for normality (complete samples)".
BIOMETRIKA 52, 591-611.
- [2]. HOEFFDING W. (1942)
"A class of statistics with asymptotically normal distribution".
THE ANNALS OF MATHEMATICAL STATISTICS
19, 293-325.
- [3]. DAVID H.A. (1970)
"Order statistics".
Wiley, New York.
- [4]. KENDALL M. and STUART A. (1979)
"The advanced theory of statistics"
Volumen 2. "Inference and relationship"
Fourth Edition.
Griffin, London.
- [5]. LOÉVE M. (1955)
"Probability theory"
Volumen 2.
Fourth Edition
Springer Verlag, New York.