



E.T.S. Ingenieros  
Industriales  
Ciudad Real



# Herramientas para aplicar la estadística y el control de calidad en las empresas



Herramientas estadísticas (EHE)

Guillermo Sánchez (<http://diarium.usal.es/guillermo>)

Presentación el 2015-04-23 :

Los datos y su representación

Algunas normas ISO aplicables al control de calidad

Herramientas de calidad disponibles para su uso en la web

## Los datos

### Distribución de la población española por pueblos

```
In[1]:= poblacionciudades = CityData[#, "Population"] & /@ CityData[{All, "Spain"}];
```

```
In[2]:= Length[poblacionciudades]
```


```
Out[2]= 8066
```

```
In[3]:= {Mean[#, StandardDeviation[#, Skewness[#, Kurtosis[#,
```

```
Quantile[#, .6], InterquartileRange[#]} &[poblacionciudades] // N
```


```
Out[3]= { 5564.95 people , 47 334.1 people , 47.9311, 3010.32, 980. people , 2168. people }
```

```
In[4]:= ListLogPlot[poblacionciudades]
```



## Agrupaciones

```
In[5]:= Manipulate[Histogram[Drop[Drop[poblacionciudades, a], -b]],
  {{a, 500}, 0, 1000, 10}, {{b, 500}, 0, 1000, 100}, SaveDefinitions -> True]
```



Drop::normal : Nonatomic expression expected at position 1 in Drop[poblacionciudades, 500]. >>

Drop::drop : Cannot drop positions -500 through -1 in Drop[poblacionciudades, 500]. >>

Histogram::ldata : Drop[Drop[poblacionciudades, 500], -500] is not a valid dataset or list of datasets. >>

Drop::normal : Nonatomic expression expected at position 1 in Drop[poblacionciudades, 500]. >>

Drop::drop : Cannot drop positions -500 through -1 in Drop[poblacionciudades, 500]. >>

Histogram::ldata : Drop[Drop[poblacionciudades, 500], -500] is not a valid dataset or list of datasets. >>


¿Que se deduce de la representación de los datos?

## Los datos multivariantes ¿Cómo representarlos?


```
In[53]:= multidata = RandomVariate[MultivariatePoissonDistribution[1, {2, 3, 4}], 125]
```

```
Out[53]:= {{5, 6, 3}, {6, 2, 5}, {4, 3, 5}, {2, 4, 8}, {3, 3, 3}, {2, 7, 4},
  {4, 6, 5}, {2, 1, 5}, {2, 3, 5}, {3, 2, 3}, {8, 11, 8}, {3, 9, 2}, {3, 2, 2},
  {2, 3, 6}, {2, 2, 7}, {5, 6, 9}, {2, 4, 1}, {3, 1, 5}, {7, 9, 8}, {3, 3, 5},
  {2, 4, 1}, {1, 3, 3}, {1, 3, 7}, {6, 5, 8}, {6, 6, 8}, {4, 2, 3}, {0, 0, 8},
  {4, 5, 4}, {5, 3, 4}, {3, 5, 8}, {2, 4, 4}, {5, 6, 6}, {1, 2, 2}, {5, 2, 2},
  {3, 6, 8}, {3, 1, 3}, {2, 2, 3}, {2, 5, 8}, {4, 6, 4}, {3, 3, 7}, {3, 2, 4},
  {4, 6, 4}, {1, 2, 4}, {4, 5, 8}, {2, 2, 0}, {3, 4, 6}, {2, 3, 5}, {2, 3, 4},
  {2, 6, 7}, {4, 3, 4}, {2, 4, 5}, {2, 6, 5}, {4, 4, 5}, {6, 6, 8}, {1, 4, 7},
  {4, 3, 4}, {4, 0, 5}, {6, 2, 10}, {4, 6, 5}, {3, 2, 4}, {4, 6, 9}, {3, 8, 5},
  {3, 3, 4}, {2, 2, 3}, {1, 2, 4}, {2, 3, 4}, {4, 2, 4}, {3, 3, 6}, {3, 2, 4},
  {3, 1, 6}, {4, 3, 4}, {5, 3, 3}, {1, 1, 2}, {3, 5, 4}, {1, 2, 2}, {3, 4, 4},
  {1, 5, 2}, {2, 10, 8}, {5, 5, 5}, {3, 3, 2}, {3, 2, 4}, {4, 2, 8}, {1, 3, 8},
  {3, 2, 1}, {4, 2, 3}, {5, 0, 10}, {2, 3, 9}, {5, 11, 9}, {3, 5, 9}, {3, 4, 5},
  {2, 3, 5}, {4, 5, 7}, {2, 3, 5}, {4, 6, 3}, {0, 4, 3}, {6, 3, 7}, {5, 1, 4},
  {3, 6, 4}, {3, 4, 1}, {3, 0, 2}, {2, 5, 6}, {1, 5, 7}, {0, 0, 3}, {3, 4, 6},
  {6, 4, 4}, {3, 5, 4}, {1, 5, 6}, {2, 3, 6}, {2, 4, 5}, {8, 8, 6}, {8, 8, 10},
  {4, 8, 10}, {2, 2, 5}, {2, 4, 5}, {4, 9, 10}, {3, 3, 6}, {3, 2, 6}, {1, 1, 6},
  {0, 5, 3}, {4, 3, 4}, {3, 4, 9}, {0, 2, 2}, {6, 8, 7}, {3, 9, 6}, {3, 2, 6}}
```



```
In[54]:= Show[{ListPointPlot3D[multidata],
  Graphics3D[{Red, PointSize[Large], Point[Mean[multidata]]}]]}]
```



```
In[55]:= Histogram3D[multidata[[All, 1 ;; 2]], 5]
```




```
In[56]:= Row[{SmoothHistogram3D[multidata[[All, 1 ;; 2]], ImageSize -> Medium],
SmoothDensityHistogram[multidata[[All, 1 ;; 2]], ImageSize -> Medium]]]
```




Aquí un conjunto de datos trivariantes son visualizados de dos formas, en un sistema de coordenadas  $x,y,z$  y un plano  $\{x, y\}$  y la coordenada  $z$  como burbujas en cuyo tamaño (la coordenada  $z$  es el radio de la burbuja).

```
In[57]:= GraphicsRow[{ListPointPlot3D[multidata, PlotStyle -> PointSize[.025]],
  BubbleChart[multidata, BubbleScale -> "Diameter",
  BubbleSizes -> {.025, .075}], ImageSize -> Medium]
```




Un conjunto de datos cuadrimensionales pueden ser representados en un gráfico de burbujas (la cuarta dimensión es el color).

```
In[10]:= BubbleChart3D[RandomReal[10, {25, 4}], ColorFunction -> "AvocadoColors"]
```



## Los datos son aleatorios pero frecuentemente siguen distribuciones de probabilidad

```
In[11]:= Manipulate[
  Histogram[RandomVariate[NormalDistribution[0, 1], a], Automatic, "PDF", Epilog ->
    First@Plot[PDF[NormalDistribution[0, 1], x], {x, -4, 4}, PlotStyle -> Red]],
  {{a, 1000, "Número de datos"}, 50, 10 000}]
```




La representación gráfica nos dirá mucho acerca de la distribución de probabilidad

```
In[12]:= data = RandomVariate[d = NormalDistribution[12, 3], 30];
```

Los representamos y los comparamos con la función de densidad de una población normal.

```
In[13]:= Show[
  Histogram[data, 5, "ProbabilityDensity"],
  Plot[PDF[NormalDistribution[12, 3], x], {x, 0, 20}, PlotStyle -> Thick]]
```



## Test de hipótesis.-

### Permiten saber si es razonable asumir que los datos siguen una determinada función de probabilidad

El planteamiento consiste en formular una hipótesis nula  $H_0: \mu = \mu_0$  frente a otra alternativa (por ej.:  $H_1: \mu \neq \mu_0$ )

Para probar  $H_0$  se toma una muestra aleatoria de la población. Se calcula una estadística de prueba apropiada, y después se rechaza o no la hipótesis nula  $H_0$ .

- Pueden cometerse dos tipos de errores:

**Error de tipo I.-  $\alpha = P\{\text{error de tipo I}\} = P\{\text{rechazar } H_0 / H_0 \text{ es verdadera}\}$**

- **Error de tipo II.-  $\beta = P\{\text{error de tipo II}\} = P\{\text{no rechazar } H_0 / H_0 \text{ es falsa}\}$**

A veces se utiliza el concepto de *potencia de la prueba*,  $P$ , que se define como

$$P = 1 - \beta = P\{\text{rechazar } H_0 / H_0 \text{ es falsa}\},$$

es decir es la probabilidad de rechazar correctamente  $H_0$

### Comentarios

- $\alpha$  es conocido como el riesgo de fabricante, o del vendedor, ya que denota la probabilidad de rechazar un lote bueno, o de dar por insatisfactorio el funcionamiento de un equipo o proceso que realmente opera correctamente.

$\beta$  es conocido como el riesgo de comprador ya que denota la probabilidad de aceptar un producto con calidad deficiente o que se permita seguir operando un equipo o proceso que realmente opera incorrectamente, y por consiguiente fabricando lotes malos.

- Un procedimiento frecuente, para aplicar una prueba de hipótesis, es fijar el valor de  $\alpha$  y después diseñar un procedimiento para obtener un valor pequeño de  $\beta$ . El riesgo de  $\beta$  en general disminuye cuando el tamaño de la muestra aumenta y se controla indirectamente. Un procedimiento de este tipo, en el que se fija el valor  $\alpha$ , tiene el problema de que solo nos indica si la hipótesis se admite o no, pero no nos proporciona información si en una prueba concreta el riesgo con el que se ha admitido (o rechazado) la hipótesis ha sido alto o bajo. Para evitar este problema es más frecuente utilizar el criterio del P-valor que definimos como el nivel de significación más pequeño con el que rechazaríamos la hipótesis nula. Este es el criterio que aplicaremos en lo que sigue.

## Test para comprobar si los datos se pueden ajustar a una determinada distribución

Aplicamos varios tests para ver la mejor función de distribución a la que se ajustan los datos


```
In[14]:=  $\mathcal{H}$  = DistributionFitTest[data, Automatic, "HypothesisTestData"];
```

```
In[15]:=  $\mathcal{H}$ ["TestDataTable", All]
```

	Statistic	P- Value
Anderson- Darling	0.302802	0.602498
Baringhaus- Henze	0.178803	0.507008
Cramér- von Mises	0.0390273	0.696079
Jarque- Bera ALM	1.31575	0.413957
Kolmogorov- Smirnov	0.0803866	0.896597
Out[15]= Kuiper	0.116025	0.867037
Mardia Combined	1.31575	0.413957
Mardia Kurtosis	-0.842636	0.399432
Mardia Skewness	0.555058	0.456258
Pearson $\chi^2$	2.	0.849145
Shapiro- Wilk	0.963348	0.376096
Watson U <sup>2</sup>	0.0354344	0.752032

Valores de P (P-Values) > 0.05 (como es el caso) indican que es razonable asumir que los datos proceden de una distribución normal.

```
In[16]:= ProbabilityPlot[data, d]
```



 **Herramientas estadísticas (EHE)**

En <http://www3.enusa.es/webMathematica/Estadistica/estadistica.htm> pueden descargarse ficheros en Word que contienen algunas normas ISO aplicables al control de calidad, con ejemplos en excel. Además se incluyen una serie de cálculos que pueden ejecutarse directamente desde el navegador.

# Técnicas de estimación y pruebas relativas a las media y varianza (ISO 2854-1976)

El procedimiento habitual en control de procesos y el control de calidad es inferir una serie de conclusiones respecto de la población a partir de una muestra de la misma. Con frecuencia supondremos que se usan *muestras aleatorias*. Es decir, se tomará una muestra  $x_1, \dots, x_n$ , de manera que las observaciones  $\{x_i\}$  se distribuyan independientemente.

Habitualmente supondremos que el muestreo es con reposición, aunque no lo sea, pues el tratamiento estadístico es más sencillo y cuando la muestra es muy pequeña comparada con la población no afectará prácticamente a las conclusiones.

## Pruebas ISO 2854 - 576

Las hipótesis más usuales a comprobar para poblaciones y muestras son relativas a las estimaciones de las medias y varianzas. En las tablas se resumen las hipótesis más usuales a comprobar. Las letras mayúsculas (A, a H) identifican el procedimiento aplicable de la ISO 2854 - 576

<b>MEDIAS</b>	Varianza conocida	Varianza desconocida
Comparación de la media con un valor dado	A	A'
Estimación de la media	B	B'
Comparación de dos medias	C	C'
Estimación de la diferencia de dos medias	D	D'

<b>Varianzas</b>	Prueba
Comparación de varianzas con un valor dado	E
Estimación de la varianza	F
Comparación de dos varianzas	G
Estimación de la razón de dos varianzas	H

Las hipótesis para la varianza son directamente extensibles a las desviaciones estándar sin más que tener en cuenta que  $\sigma = \sqrt{\sigma^2}$

En todos los test es necesario fijar previamente el nivel de significación  $\alpha$  (usualmente se elige  $\alpha = 0.01$ , o  $\alpha = 0.05$ )

## A.- Comparación de $\mu$ con un valor dado $m_0$ con $\sigma^2$ conocida.

Sea  $\mu$  la media de una población (no necesariamente normal), de varianza  $\sigma^2$  conocida. Tomemos una muestra con media  $\bar{x}$  y tamaño  $n$ . Comparamos  $\mu$  con un valor dado  $m_0$  para los siguientes casos :

- Hipotesis nula  $H_0: \mu = m_0$ . La hipótesis se rechaza si:

$$|\bar{x} - m_0| > z_{1-\alpha/2} \frac{\sigma}{\sqrt{n}} \quad (1)$$

- Hipotesis nula  $H_0: \mu \geq m_0$ . La hipótesis se rechaza si:

$$\bar{x} < m_0 - z_{1-\alpha} \frac{\sigma}{\sqrt{n}} \quad (2)$$

- Hipotesis nula  $H_0: \mu \leq m_0$ . La hipótesis se rechaza si:

$$\bar{x} > m_0 + z_{1-\alpha} \frac{\sigma}{\sqrt{n}} \quad (3)$$

### Ejemplo 1

Uno de los criterios de aceptación establecidos para utilizar botellas de vidrio, usadas para embasar bebidas gaseosas, es que la resistencia media a la presión interna sea mayor de 175 psi. Una embotelladora recibe una muestra de 25 botellas obteniendo los siguientes valores, en psi : {199, 198, 201, 185, 182, 172, 170, 177, 189, 198, 173, 177, 171, 179, 168, 185, 180, 169, 175, 191, 181, 182, 182, 187, 179}. El fabricante informa que su proceso presenta una desviación estándar  $\sigma = 10$  psi. ¿Pueden reutilizarse las botellas de este fabricante?.

Comenzamos por elaborar una lista con los datos del ejemplo, que llamamos  $pI$ , de presión interna  $pI$ , y calculamos su media que llamaremos  $\bar{x}_{pI}$ :

```
In[17]:= pI = {199, 198, 201, 185, 182, 172, 170, 177, 189, 198, 173, 177, 171, 179, 168, 185, 180, 169, 175, 191, 181, 182, 182, 187, 179};
```

```
In[18]:=  $\bar{x}_{pI}$  = Mean[pI]
```

```
Out[18]= 182
```

Se trata de probar la hipótesis con  $\mu \geq m_0$  con  $m_0 = 175$  psi. Para ellos aplicamos (3) fijando un nivel de significación  $\alpha = 5\%$ .

Ahora sustituimos en (3), donde  $m_0 = 175$  psi y  $\sigma = 10$  psi .

```
In[19]:= z[c_] := Quantile[NormalDistribution[0, 1], c]
```

```
In[20]:= n = Length[pI]
```

```
Out[20]= 25
```

```
In[21]:= LS = 175 +  $\frac{10}{\sqrt{n}}$  z[0.95]
```

```
Out[21]= 178.29
```

```
In[22]:=  $\bar{x}_{pI} \geq LS$ 
```

```
Out[22]= True
```

Conclusión : La hipótesis nula  $H_0 : \mu \leq m_0$  es rechazada, por tanto se puede considerar admisible la hipótesis alternativa  $H_1 : \mu > m_0$ . Es decir se pueden admitir las botellas para su reutilización

Nota : El test anterior está incorporado en ref/Ztest

```
In[23]:= ZTest [pI, 102, 175, AlternativeHypothesis → "Less"]
```

```
Out[23]= 0.999767
```

## A'.- Comparación de $\mu$ con un valor dado $m_0$ con $\sigma^2$ desconocida.

Sea  $\mu$  la media de una población (no necesariamente normal), de varianza conocida  $\sigma^2$ . Tomemos una muestra con media  $\bar{x}$  y desviación estandar muestral  $S$ , tamaño  $n$ . Comparamos  $\mu$  con un valor dado  $m_0$  para los siguientes casos :

- Hipotesis nula  $H_0: \mu = m_0$ . La hipótesis se rechaza si:

$$|\bar{x} - m_0| > t_{(1-\alpha/2, \nu)} \frac{S}{\sqrt{n}} \quad (4)$$

- Hipotesis nula  $H_0: \mu \geq m_0$ . La hipótesis se rechaza si:

$$\bar{x} < m_0 - t_{(1-\alpha, \nu)} \frac{S}{\sqrt{n}} \quad (5)$$

- Hipotesis nula  $H_0: \mu \leq m_0$ . La hipótesis se rechaza si:

$$\bar{x} > m_0 + t_{(1-\alpha, \nu)} \frac{S}{\sqrt{n}} \quad (6)$$

### Ejemplo 2

Repetir el ejercicio anterior asumiendo como estimador de varianza el de la muestra.

Empezaremos por calcular la desviación standardzde de la lista pI (la media es la antes calculada)

```
In[24]:= SpI = StandardDeviation[pI]
```

```
Out[24]= 3  $\sqrt{\frac{21}{2}}$ 
```

se trata de probar la hipótesis  $\mu \geq m_0$  con  $m_0 = 175$  psi. Para ello aplicamos (5) fijando un nivel de significación  $\alpha = 5\%$ .

Determinar el valor de  $z_{1-\alpha}$

```
In[25]:= t[c_] := Quantile[StudentTDistribution[Length[pI] - 1], c]
```

Ahora sustituimos en (5), donde  $m_0 = 175$  psi.

```
In[26]:=  $\bar{x}_{pI} <= 175 + \frac{S_{pI}}{\sqrt{n}} t[0.95]$ 
```

```
Out[26]= False
```

Conclusión : La hipótesis nula  $H_0 : \mu \leq m_0$  es rechazada . Es admisible la hipótesis alternativa  $H_1 : \mu > m_0$  , por tanto se pueden admitir las botellas para su reutilización

Nota : El test anterior está incorporado en ref/AlternativeHypothesis

```
In[27]:= LocationTest[pI, 175, AlternativeHypothesis -> "Less", SignificanceLevel -> .05]
```

```
Out[27]= 0.999282
```

## B.- Estimación de $\mu$ para una población con varianza $\sigma^2$ conocida.

Sea una población con media  $\mu$ , no necesariamente normal, con varianza  $\sigma^2$  conocida. Tomemos una muestra con media  $\bar{x}$  y tamaño  $n$ . Se trata de estimar  $\mu$  para los siguientes casos:

- Intervalo de confianza bilateral

$$\bar{x} - z_{1-\alpha/2} \frac{\sigma}{\sqrt{n}} < \mu < \bar{x} + z_{1-\alpha/2} \frac{\sigma}{\sqrt{n}} \quad (7)$$

- Intervalos de confianza unilaterales

$$\mu < \bar{x} + z_{1-\alpha} \frac{\sigma}{\sqrt{n}} \quad (8)$$

$$\mu > \bar{x} - z_{1-\alpha} \frac{\sigma}{\sqrt{n}} \quad (9)$$

### Ejemplo 3

Calcular el intervalo de confianza para la media de la lista del ejemplo 1. Asumir que  $\sigma = 10$ .

Podemos resolverlo utilizando la ecuación (7) o más directamente utilizando `NormalCI` del paquete `HypothesisTesting` que la incorpora.

```
In[28]:= { $\bar{x}_{pI} - \frac{10}{\sqrt{n}} z[0.975]$ ,  $\bar{x}_{pI} + \frac{10}{\sqrt{n}} z[0.975]$ }
```

```
Out[28]:= {178.08, 185.92}
```

```
In[29]:= Needs["HypothesisTesting`"]
```

```
In[30]:= MeanCI[pI, KnownVariance -> 10^2]
```

```
Out[30]:= {178.08, 185.92}
```

## B'.- Estimación de $\mu$ para una población con varianza $\sigma^2$ desconocida.

Sea una población con media  $\mu$ , no necesariamente normal, con varianza  $\sigma^2$  desconocida.

Tomemos una muestra con media  $\bar{x}$ , desviación estandar  $s$ , tamaño  $n$  y grados de libertad  $\nu = n - 1$ .

1. Se trata de estimar el intervalo de confianza de  $\mu$  para los siguientes casos

- Intervalo de confianza bilateral

$$\bar{x} - t_{(1-\alpha/2, \nu)} \frac{s}{\sqrt{n}} < \mu < \bar{x} + t_{(1-\alpha/2, \nu)} \frac{s}{\sqrt{n}} \quad (10)$$

- Intervalos de confianza unilaterales

$$\mu < \bar{x} + t_{(1-\alpha, \nu)} \frac{s}{\sqrt{n}} \quad (11)$$

$$\mu > \bar{x} - t_{(1-\alpha, \nu)} \frac{s}{\sqrt{n}} \quad (12)$$

### Ejemplo 4

Un dosificador para el emvasado de un producto farmaceutico ha estado parado 2 meses. Se vuelve a poner en marcha, se sabe que anteriormente el peso medio emvasado era  $\mu = 13.58$  pero se desconoce el valor de  $\sigma$ . Se sospecha que el proceso puede estar desajustado. Para comprobarlo se toma una muestra de 12 unidades obteniendose para esta muestra  $\bar{x} = 13.70$  y  $s = 0.146$ . ¿Esta el proceso desajustado (apliquese un nivel de significacion del 1 %)?

Lo podemos resolver directamente aplicando la ec(10)

```
In[31]:= t0.99,11 = Quantile[StudentTDistribution[12 - 1], 0.99]
```

```
Out[31]= 2.71808
```

```
In[32]:= LS = 13.58 + t0.99,11 * (0.146 / Sqrt[12 - 1])
```

```
Out[32]= 13.6997
```

Es decir, la región de aceptación vendrá dado por todos los valores  $\bar{x} \leq 13.6997$  y la de rechazo  $\bar{x} > 13.6997$ . Como 13.70 esta fuera de la región de aceptación admitiremos que el dosificador esta desajustado.

Al mismo resultado podemos llegar utizando StudentTCI del paquete HypothesisTesting (Ojo: este paquete asume un intervalo bilateral por eso el nivel de confianza es 0.01 en cada sentido, es decir, el total es 0.02)

```
In[33]:= ? StudentTCI
```

StudentTCI[ $\mu, \sigma, df$ ] gives a confidence interval based on Student's  $t$  distribution with  $df$  degrees of freedom. >>

```
In[34]:= StudentTCI[13.58, 0.146 / Sqrt[11], 11, ConfidenceLevel -> 0.98] [[2]]
```

```
Out[34]= 13.6997
```

## C.- Comparación de $\mu_1$ y $\mu_2$ , de poblaciones con $\sigma_1^2$ y $\sigma_2^2$ conocidas.

Sea las medias,  $\mu_1$  y  $\mu_2$ ,

de poblaciones (no necesariamente normales) con varianzas  $\sigma_1^2$  y  $\sigma_2^2$  conocidas.

Tomamos una muestra de cada población, con medias  $\bar{x}_1$  y  $\bar{x}_2$  tamaños  $n_1$  y  $n_2$ . Calculamos

$$\sigma_d = \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}} \quad (13)$$

Comparamos  $\mu_1$  y  $\mu_2$  para los siguientes casos:

- Hipotesis nula  $H_0: \mu_1 = \mu_2$ . La hipótesis se rechaza si:

$$| \bar{x}_1 - \bar{x}_2 | > z_{1-\alpha/2} \sigma_d \quad (14)$$

- Hipotesis nula  $H_0: \mu_1 \geq \mu_2$ . La hipótesis se rechaza si:

$$\bar{x}_1 < \bar{x}_2 - z_{1-\alpha} \sigma_d \quad (15)$$

- Hipotesis nula  $H_0: \mu_1 \leq \mu_2$ . La hipótesis se rechaza si:

$$\bar{x}_1 > \bar{x}_2 + z_{1-\alpha} \sigma_d \quad (16)$$

### Ejemplo 5

Una fabrica produce un alambre de cobre con un alargamiento medio  $\bar{x}_1 = 27.9\%$  y  $\sigma_1 = 2.64\%$ , obtenidos del resultado de 30 medidas. Se prueba un nuevo procedimiento de fabricación. Se toma una muestra de 13 unidades a partir de la cual obtiene una media  $\bar{x}_2 = 28.7\%$  (se asume el mismo valor de  $\sigma$ ). ¿Puede considerarse que el proceso sigue garantizando el mismo nivel máximo de alargamiento?.

Se trata de probar la hipótesis  $H_0: \mu_1 \geq \mu_2$ , para lo cual aplicamos (15). Previamente necesitamos calcular  $\sigma_d$  dado por (13) y continuación aplicaremos (15) aplicando un nivel de significación  $\alpha=5\%$

```
In[35]:= Clear["Global`*"]
```

```
In[36]:=  $\sigma_d = \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}} ;$ 
```

```
In[37]:= z[c_] := Quantile[NormalDistribution[0, 1], c]
```

```
In[38]:=  $\bar{x}_1 = 27.9; \bar{x}_2 = 28.7;$ 
```

```
In[39]:= LI =  $\bar{x}_2 - z[0.95] \sigma_d /. \{\sigma_1 \rightarrow 2.64, \sigma_2 \rightarrow 2.64, n_1 \rightarrow 30, n_2 \rightarrow 13\}$ 
```

```
Out[39]:= 27.2581
```

```
In[40]:=  $\bar{x}_1 <= LI$ 
```

```
Out[40]:= False
```

Es decir, se admite la hipótesis  $H_0: \mu_1 \geq \mu_2$ , y por tanto se acepta que el nuevo proceso mantiene el mismo nivel máximo de alargamiento.

## C'.- Comparación de $\mu_1$ y $\mu_2$ , de poblaciones con $\sigma_1^2$ y $\sigma_2^2$ desconocidas.

Sea las medias,  $\mu_1$  y  $\mu_2$ , de poblaciones (no necesariamente normales) con varianzas  $\sigma_1^2$  y  $\sigma_2^2$ , desconocidas pero que se pueden asumir iguales. Tomemos una muestra de cada población, con medias  $\bar{x}_1$  y  $\bar{x}_2$ , tamaños  $n_1$  y  $n_2$ , y calculemos:

$$s_d = \sqrt{\frac{n_1 + n_2}{n_1 n_2} \frac{\sum (x_1 - \bar{x}_1)^2 + \sum (x_2 - \bar{x}_2)^2}{n_1 + n_2 - 2}} \quad (17)$$

Compararemos  $\mu_1$  y  $\mu_2$  para los siguientes casos:

- Hipotesis nula  $H_0: \mu_1 = \mu_2$ . La hipótesis se rechaza si:

$$| \bar{x}_2 - \bar{x}_1 | > t_{(1-\alpha/2, \nu)} s_d \quad (18)$$

- Hipotesis nula  $H_0: \mu_1 \geq \mu_2$ . La hipótesis se rechaza si:

$$\bar{x}_1 < \bar{x}_2 - t_{(1-\alpha, \nu)} s_d \quad (19)$$

- Hipotesis nula  $H_0: \mu_1 \leq \mu_2$ . La hipótesis se rechaza si:

$$\bar{x}_1 > \bar{x}_2 + t_{(1-\alpha, \nu)} s_d \quad (20)$$

### Ejemplo 6

Una compañía petrolera pronto debe dejar de vender gasolina que contiene tetraetil-plomo que sustituirá por otra libre de plomo. Para la gasolina sin plomo pretende conservar el mismo índice octánico. Para ello realiza 10 medidas del índice octanico en cada uno de las gasolinas. Los resultados se muestran a continuación. ¿Puede asumirse que el índice octanico de ambos tipos de gasolina es el mismo? . (Se aplicará para un intervalo de confianza del 99% y se asumira varianzas desconocidas e iguales.)

```
In[41]= plomo = {89.5, 90.0, 91.0, 91.5, 92.5, 91.0, 89.0, 89.5, 91.0, 92.0};
sinplomo = {89.5, 91.5, 91.0, 89.0, 91.5, 92.0, 92.0, 90.5, 90.0, 91.0};
```

Se trata de probar la hipótesis de que las medias son iguales. Puede hacerse calculando el p-valor y aceptando la hipótesis si  $p > 0.05$

```
In[44]= LocationTest[{plomo, sinplomo},
VerifyTestAssumptions -> "EqualVariance", SignificanceLevel -> .01]
```

```
Out[44]= 0.840909
```

Por tanto se acepta la hipótesis de que ambas gasolinas presentan el mismo índice octanico.

## D.- Estimación de la diferencia de $\mu_1$ y $\mu_2$ de dos poblaciones con $\sigma_1^2$ y $\sigma_2^2$ , conocidas.

Sean  $\mu_1$  y  $\mu_2$  las medias de dos poblaciones (no necesariamente normales) con varianzas  $\sigma_1^2$  y  $\sigma_2^2$ , conocidas. Tomemos una muestra, con medias  $\bar{x}_1$  y  $\bar{x}_2$ , tamaños  $n_1$  y  $n_2$ , y calculamos:

$$\sigma_d = \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}} \quad (21)$$

Estimemos el intervalo de confianza para la diferencia entre  $\mu_1$  y  $\mu_2$ .

- Intervalo de confianza bilateral

$$(\bar{x}_1 - \bar{x}_2) - z_{(1-\alpha/2)} \sigma_d < \mu_1 - \mu_2 < (\bar{x}_1 - \bar{x}_2) + z_{(1-\alpha/2)} \sigma_d \quad (22)$$

- Intervalos de confianza unilaterales

$$\mu_1 - \mu_2 < (\bar{x}_1 - \bar{x}_2) + z_{(1-\alpha)} \sigma_d \quad (23)$$

$$\mu_1 - \mu_2 > (\bar{x}_1 - \bar{x}_2) - z_{(1-\alpha)} \sigma_d \quad (24)$$

### Ejemplo 7

Utilizando los datos del índice octánico del ejercicio 6, y asumiendo que las varianzas obtenidas son aproximadamente las de la población. ¿Puede considerarse que la diferencia entre las medias de ambos tipos de gasolina son iguales?

Podemos aplicar las ecs(21) y (22) o utilizar el paquete `ConfidenceIntervals` que ya las incluye. Consideraremos un nivel de confianza del 95%.

```
In[45]:= ?? MeanDifferenceCI
```

```
MeanDifferenceCI[list1, list2] gives a confidence interval
for the difference between the population means estimated from list1 and list2. >>
```

```
Attributes[MeanDifferenceCI] = {Protected, ReadProtected}
```

```
Options[MeanDifferenceCI] =
{ConfidenceLevel -> 0.95, KnownVariance -> None, EqualVariances -> False}
```

```
In[46]:= MeanDifferenceCI[plomo, sinplomo, ConfidenceLevel -> 0.95]
```

```
Out[46]:= {-1.1326, 0.932599}
```

El valor "0" (diferencia de medias) está comprendido en el intervalo anterior y por tanto se puede admitir que la diferencia de medias es nula.

## D'.- Estimación de la diferencia de $\mu_1$ y $\mu_2$ de dos poblaciones con $\sigma_1^2$ y $\sigma_2^2$ , desconocidas.

Sean  $\mu_1$  y  $\mu_2$  las medias de dos poblaciones (no necesariamente normales), con varianzas,  $\sigma_1^2$  y  $\sigma_2^2$ , desconocidas. Tomemos una muestra de cada población, con medias  $\bar{x}_1$  y  $\bar{x}_2$  y tamaños  $n_1$  y  $n_2$ , y calculamos:

$$s_d = \sqrt{\frac{n_1 + n_2}{n_1 n_2} \frac{\sum (x_1 - \bar{x}_1)^2 + \sum (x_2 - \bar{x}_2)^2}{n_1 + n_2 - 2}} \quad (25)$$

Estimemos el intervalo de confianza para la diferencia entre  $\mu_1$  y  $\mu_2$ .

- Intervalo de confianza bilateral

$$\begin{aligned} (\bar{x}_1 - \bar{x}_2) - t_{(1-\alpha/2, \nu)} s_d < \\ \mu_1 - \mu_2 < (\bar{x}_1 - \bar{x}_2) + t_{(1-\alpha/2, \nu)} s_d \end{aligned} \quad (26)$$

- Intervalos de confianza unilaterales

$$\mu_1 - \mu_2 < (\bar{x}_1 - \bar{x}_2) + t_{(1-\alpha, \nu)} s_d \quad (27)$$

$$\mu_1 - \mu_2 > (\bar{x}_1 - \bar{x}_2) - t_{(1-\alpha, \nu)} s_d \quad (28)$$

### Ejemplo 8

Se toman muestras de dos tipos de gasolina: con plomo y otra sin plomo. Se mide el índice octánico (los valores son los del ejemplo 6). ¿Podemos considerar que la gasolina con plomo y sin plomo presentan el mismo índice octánico medio. (Se asumirá varianzas desconocidas e iguales.)

```
In[47]:= MeanDifferenceCI[plomo, sinplomo,
  ConfidenceLevel -> 0.95, EqualVariances -> True ]
```

```
Out[47]:= {-1.13162, 0.931617}
```

El valor "0" (diferencia de medias) está comprendido en el intervalo anterior y por tanto se puede admitir que la diferencia de medias es nula.

## F.- Estimación de la varianza

Considerese la variable aleatoria  $x$  normal. Se selecciona una muestra aleatoria  $x_1, \dots, x_n$ . Se calcula su varianza muestral  $s^2$ . Podemos construir el intervalo de confianza para  $\sigma^2$  como sigue:

- Caso bilateral

$$\frac{(n - 1) s^2}{\chi^2_{1-\alpha/2, n-1}} < \sigma^2 < \frac{(n - 1) s^2}{\chi^2_{\alpha/2, n-1}} \tag{29}$$

- Caso unilaterales

$$\sigma^2 < \frac{(n - 1) s^2}{\chi^2_{\alpha, n-1}} \tag{30}$$

$$\sigma^2 > \frac{(n - 1) s^2}{\chi^2_{1-\alpha, n-1}} \tag{31}$$

Para obtener información sobre la distribución  $\chi^2$  o `ChiSquareDistribution` podemos utilizar la ayuda en la forma habitual

```
In[48]:= ? ChiSquareDistribution*
```

ChiSquareDistribution[ $\nu$ ] represents a  $\chi^2$  distribution with  $\nu$  degrees of freedom. >>

Cuya función de densidad es:

```
In[49]:= PDF[ChiSquareDistribution[n], x]
```

$$\text{Out[49]} = \begin{cases} \frac{2^{-n/2} e^{-x/2} x^{-1+\frac{n}{2}}}{\text{Gamma}[\frac{n}{2}]} & x > 0 \\ 0 & \text{True} \end{cases}$$

### Ejemplo 9

Un fabricante está interesado en la determinación de la resistencia a la rotura de un determinado tipo de fibras sintéticas. Una muestra de 16 fibras da como presión de rotura la de la lista: fibra1. Por experiencias anteriores se considera que los valores están normalmente distribuidas. ¿Entre que valores estará comprendida la media y la varianza (calculadas con un 95% de intervalo de confianza)?

```
In[50]:= fibra1 = { 48.89, 52.07, 49.29, 51.66, 52.16, 49.72, 48.00, 49.96, 49.20, 48.10, 47.90, 46.94, 51.76, 50.75, 49.86, 51.76};
```

El intervalo de confianza de la media esta dado por:

```
In[51]:= MeanCI[fibra1]
```

```
Out[51]:= { 48.9838, 50.7687 }
```

El intervalo de confianza para la varianza se obtiene aplicando la ec(19) que esta incluida en `VarianceCI`:

```
In[52]:= VarianceCI[fibra1]
```

```
Out[52]:= { 1.53076, 6.71946 }
```

Calcular el intervalo de confianza para la varianza del ejemplo anterior

```
In[53]:= ChiSquareCI[0.146^2, 12 - 1, ConfidenceLevel -> 0.95]
```

```
Out[53]= {0.0106969, 0.0614495}
```

## G.- Comparación de dos varianzas.

Sea  $x_1 \sim N(\mu_1, \sigma_1^2)$  y  $x_2 \sim N(\mu_2, \sigma_2^2)$ , donde  $\mu_1, \sigma_1^2, \mu_2, \sigma_2^2$  son desconocidas: deseamos construir un intervalo de confianza para  $s_1^2 / s_2^2$ , donde  $s_1^2$  y  $s_2^2$  son varianzas muestrales obtenida, respectivamente, de  $n_1$  y  $n_2$  observaciones aleatorias.

- Hipotesis nula  $H_0: s_1^2 = s_2^2$ . Se rechaza si:

$$\frac{s_1^2}{s_2^2} < \frac{1}{F_{1-\alpha/2, n_2-1, n_1-1}},$$

$$\frac{s_1^2}{s_2^2} > F_{1-\alpha/2, n_1-1, n_2-1} \quad (32)$$

- Hipotesis nula  $H_0: s_1^2 \leq s_2^2$ . Se rechaza si:

$$\frac{s_1^2}{s_2^2} > F_{1-\alpha, n_1-1, n_2-1} \quad (33)$$

- Hipotesis nula  $H_0: s_1^2 \geq s_2^2$ . Se rechaza si:

$$\frac{s_1^2}{s_2^2} < \frac{1}{F_{1-\alpha, n_2-1, n_1-1}} \quad (34)$$

### Ejemplo 10

Deseamos conocer si debemos asumir la hipótesis utilizada en el ejemplo 6 de varianzas iguales.

Se trata de contrastar la hipótesis  $H_0: \sigma_1^2 = \sigma_2^2$  frente a la alternativa  $H_1: \sigma_1^2 \neq \sigma_2^2$ . Aplicamos el test para contrastar la hipótesis de la razón de varianzas  $F_0 = s_1^2 / s_2^2 = 1$  frente a  $F_1 = s_1^2 / s_2^2 \neq 1$ .

La hipótesis nula  $F_0 = 1$  no puede ser rechazada para como  $\alpha = 0.05$  ni para cualquier nivel de significación de  $\alpha \geq p = 0.73$

```
In[54]:= VarianceEquivalenceTest[{plomo, sinplomo}]
```

```
Out[54]= 0.735885
```

## H.- Estimación de la razón de dos varianzas $\sigma_1^2 / \sigma_2^2$

Sea  $x_1 \sim N(\mu_1, \sigma_1^2)$  y  $x_2 \sim N(\mu_2, \sigma_2^2)$ . Deseamos construir un intervalo de confianza para  $\sigma_1^2 / \sigma_2^2$ . Conocemos las varianzas muestrales  $S_1^2$  y  $S_2^2$  obtenidas de  $n_1$  y  $n_2$  observaciones aleatorias. Para ello procedemos como sigue:

- Caso bilateral

$$\frac{1}{F_{1-\alpha/2, n_1-1, n_2-1}} \frac{S_1^2}{S_2^2} < \frac{\sigma_1^2}{\sigma_2^2} < F_{1-\alpha/2, n_2-1, n_1-1} \frac{S_1^2}{S_2^2} \quad (35)$$

- Casos unilaterales

$$\begin{aligned} \frac{\sigma_1^2}{\sigma_2^2} &> \frac{S_1^2}{S_2^2} \frac{1}{F_{1-\alpha, n_1-1, n_2-1}} \quad \circ \\ \frac{\sigma_1^2}{\sigma_2^2} &< \frac{S_1^2}{S_2^2} F_{1-\alpha, n_2-1, n_1-1} \end{aligned} \quad (36)$$

### Ejemplo 11

Consideremos los valores del índice de octanaje del ejemplo anterior. Nos planteamos si podemos asumir la hipótesis utilizada de suponer varianzas iguales

In[55]:= `? VarianceRatioCI`

VarianceRatioCI[list1, list2] gives a confidence interval for the ratio of the population variances estimated from list1 and from list2. >>

In[56]:= `VarianceRatioCI[plomo, sinplomo]`

Out[56]:= `{0.31307, 5.07443}`

Como "1" está comprendido en el intervalo anterior no rechazamos la hipótesis  $S_1^2 / S_2^2 = 1$

## I.- Comparación de medias en el caso de datos apareados (ISO 3301-1975(E))

Sean dos observaciones  $x_i$  e  $y_i$  de cierta propiedad o característica. Se dice que son datos apareados si:

- a) Corresponden a la observación del mismo elemento  $i$  pero bajo diferentes condiciones,
- b) Corresponden a dos elementos que se pueden considerar similares en todos los aspectos para la característica que es objeto del test.

Condiciones de aplicación: La serie  $d_i = x_i - y_i$ , son valores aleatorios independientes, con media  $\bar{d}$  y media  $\sigma_d \approx s_d$ , que se supone siguen aproximadamente una distribución normal.

Hipotesis nula  $H_0: \bar{d} = d_0$ . La hipotesis se rechaza si:

$$\left| \bar{d} - d_0 \right| > t_{(1-\alpha/2, \nu)} \frac{\sigma_d}{\sqrt{n}} \tag{37}$$

Hipotesis nula  $H_0: \bar{d} \leq d_0$ . La hipotesis se rechaza si:

$$\bar{d} < d_0 - t_{(1-\alpha, \nu)} \frac{\sigma_d}{\sqrt{n}} \tag{38}$$

Hipotesis nula  $H_0: \bar{d} > d_0$ . La hipotesis se rechaza si:

$$\bar{d} > d_0 - t_{(1-\alpha, \nu)} \frac{\sigma_d}{\sqrt{n}} \tag{39}$$

Samples were drawn from a pool of water at 10 randomly selected locations. Each sample was tested for zinc concentration at both the surface of the water and the bottom of the pool:

```
In[57]:= bottom = {.430, .266, .567, .531, .707, .716, .651, .589, .469, .723};
         surface = {.415, .238, .390, .410, .605, .609, .632, .523, .411, .612};
```

```
In[59]:= LocationTest[{bottom, surface}, 0,
                    {"TestDataTable", "PairedT"}, AlternativeHypothesis -> "Greater"]
```

	Statistic	P-Value
Out[59]= Paired T	4.86381	0.000445558

## J.-Test de hipótesis para para parámetros binomiales

In[142]:= Quit[]

In[1]:= z[c\_] := Quantile[NormalDistribution[0, 1], c]

A veces en vez de un valor dado por una variable continua lo que tenemos es que un ítem cuya inspección es se rechaza o se acepta (pasa, no pasa) sin que este se le mida un valor concreto: Por ejemplo: disponemos de un anillo a través del cual se hace pasar el ítem: este pasa o no pasa. En estos casos hablamos de parámetros binomiales

### Comparación de p con un valor dado $p_0$

Deseamos comprobar la hipótesis  $H_0 : p = p_0$  (Parámetro binomial p con un valor dado  $p_0$ ) frente a la hipótesis alternativa  $H_1 : p \neq p_0$ . Aplicaremos la aproximación a la distribución normal de la binomial. Para comprobar la hipótesis anterior tomamos una muestra aleatoria n de x ítems.

$$Z_0 = \frac{(x + 0.5) - n p_0}{\sqrt{n p_0 (1 - p_0)}} \text{ si } x \leq n p_0 \quad (40)$$

$$Z_0 = \frac{(x - 0.5) - n p_0}{\sqrt{n p_0 (1 - p_0)}} \text{ si } x > n p_0 \quad (41)$$

- La hipótesis nula  $H_0 : p = p_0$  se rechaza si  $|Z_0| > Z_{\alpha/2}$

### Ejemplo

Un taller fabrica frenos para la industria del automóvil. Deseamos comprobar si el proceso produce un rechazo del 10%. Para ello tomamos una muestra de 250 uds y encontramos que 41 son defectuosos (usar un nivel de significación  $\alpha=0.05$ ).

Se trata de comprobar  $H_0 : p = 0.1$  frente a  $H_1 : p \neq p_0$ . Se trata de calcular  $Z_0$  para lo que aplicamos (40)

In[2]:=  $Z_0 = \frac{(41 - 0.5) - 250 * 0.1}{\sqrt{250 * 0.1 (1 - 0.1)}}$

Out[2]= 3.26769

Calculamos  $z_{1+0.05/2}$  y lo comparamos con  $Z_0$

In[3]:= Abs[Z\_0] > z[1 - 0.05 / 2]

Out[3]= True

Conclusión: La hipótesis nula  $H_0 : p = 0.1$  deberá ser rechazada

## Comparación de dos parametros binomiales: $p_1$ y $p_2$

Deseamos comprobar la hipótesis de igualdad de dos parametros binomiales  $H_0 : p_1 = p_2$  frente a la hipótesis alternativa  $H_1 : p_1 \neq p_2$ . Aplicaremos la aproximación a la distribución normal de la binomial. Para comprobar la hipótesis anterior tomamos una muestra aleatoria de  $n_1$  observaciones de la población 1 y de  $n_2$  de la población 2. Supondremos que  $x_1$  y  $x_2$  son el número de items defectuosos en cada muestra. Los parametros binomiales para cada muestra son:  $\hat{p}_1 = x_1 / n_1$  y  $\hat{p}_2 = x_2 / n_2$ . Entonces si la hipótesis nula es cierta:  $p = p_1 = p_2$  y los dos estimadores muestrales pueden ser combinados en un estimador conjunto:

$$\hat{p} = \frac{n_1 \hat{p}_1 + n_2 \hat{p}_2}{n_1 + n_2} \quad (42)$$

El estadístico para comprobar  $H_0$  es:

$$Z_0 = \frac{\hat{p}_1 - \hat{p}_2}{\sqrt{\hat{p} (1 - \hat{p}) \left( \frac{1}{n_1} + \frac{1}{n_2} \right)}} \quad (43)$$

- La hipótesis nula  $H_0 : p_1 = p_2$  se rechaza si  $|Z_0| > Z_{\alpha/2}$

### Ejemplo

Cierto número de individuos padecen una misma enfermedad. Se dividen en dos grupos A, formado por 92 pacientes y B, por 83. Se le administra un nuevo farmaco Neopharmacol al grupo A pero no al B, por lo demás ambos grupos son tratados idénticamente. El número de pacientes recuperados de la enfermedad en el grupo A son 66 y 54 en el B. ¿Mejora el Neopharmacol el tratamiento? (usar un nivel de significación  $\alpha=0.05$ ).

Hacemos la hipótesis de que el Neopharmacol no mejora el tratamiento, es decir: suponemos que la probabilidad de recuperación de ambos grupos son iguales. Se trata de comprobar la hipótesis

$H_0 : p_A = p_B$ , frente a la alternativa:  $H_1 : p_A > p_B$

Para evitar ambigüedades en los símbolos que vamos a utilizar los definimos previamente utilizando el paquete `Notation`

```
In[4]:= Needs["Notation`"]
```

```
In[5]:= Symbolize[nA];
Symbolize[nB];
Symbolize[p]
```

```
In[16]:= nA = 92
```

```
Out[16]= 92
```

```
In[17]:= nB = 83
```

```
Out[17]= 83
```

In[18]:=  $pA = 66 / nA // N$

Out[18]= 0.717391

In[19]:=  $pB = 54 / nB // N$

Out[19]= 0.650602

In[20]:=  $\hat{p} = \frac{nA pA + nB pB}{nA + nB} // N$

Out[20]= 0.685714

- La hipótesis nula  $H_0 : p_1 = p_2$  se rechaza si  $|Z_0| > Z_{\alpha/2}$

Calculamos  $z_{1-0.05}$  y lo comparamos con  $Z_0$

Conclusión: La hipótesis nula  $H_0 : p_A = p_B$  deberá ser aceptada y por tanto no podemos decir que NeoPharmacol mejore el tratamiento

## K.- Intervalos de confianza para parámetros binomiales

A veces es necesario construir el intervalo de confianza  $100(1-\alpha)\%$  para una distribución para el parámetro  $p$  de una distribución binomial. Este parámetro corresponde a la fracción no conforme (rechazada) de un lote o proceso. Asumimos que  $n$  es conocido. Si de una muestra aleatoria  $n$  una cantidad  $n_1$  es no conforme entonces un estimador de la media  $p$  es  $\bar{p} = \frac{n_1}{n}$ . Hay varias aproximaciones para construir el intervalo de confianza. Si  $n$  es grande y  $p \geq 0.1$ , entonces puede utilizarse la aproximación normal, resultando un intervalo de confianza  $100(1-\alpha)\%$ .

$$\bar{p} - Z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq p \leq \bar{p} + Z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \tag{44}$$

con  $\sigma^2 = \bar{p} (1 - \bar{p})$

Si  $n$  es pequeño, entonces se utiliza directamente la distribución binomial para establecer los intervalos de confianza de  $p$ . Si  $n$  es grande y  $p$  es pequeño ( $<1$ ), entonces la distribución de Poisson es adecuada.

En el caso de 2 parámetros binomiales,  $p_1$  y  $p_2$  entonces podemos construir el intervalo de confianza  $100(1-\alpha)\%$  para las diferencias como sigue:

$$\bar{p}_1 - \bar{p}_2 - Z_{\alpha/2} \sqrt{\frac{\sigma_1}{n_1} + \frac{\sigma_2}{n_2}} \leq p_1 - p_2 \leq \bar{p}_1 - \bar{p}_2 + Z_{\alpha/2} \sqrt{\frac{\sigma_1}{n_1} + \frac{\sigma_2}{n_2}} \tag{45}$$

con  $\bar{p}_i = \frac{n_i}{n}$  y  $\sigma_i^2 = \bar{p}_i (1 - \bar{p}_i)$ ,  $i = 1, 2$

De una muestra aleatoria de 80 cojinetes de cigueñales 15 presentan un rugosidad mayor que la permitida en la especificación correspondiente. ¿Cuales son los límites del intervalo, calculados con un 95% de confianza, par la fracción no conforme? , ¿Puede asumirse la aproximación de la binomial a la normal?.

La fracción media de elementos no conformes es  $\bar{p} = 15/80 \geq 0.1$  por tanto y  $n$  es grande, por tanto sí puede utilizarse la aproximación de la binomial por una normal para estimar el intervalo de confianza de los elementos no conformes. Por tanto puede aplicarse la ecuación (40)

In[21]:=  $\bar{p} = 15 / 80$

Out[21]=  $\frac{3}{16}$

In[22]:= **intervalo** =  $\sqrt{\frac{\bar{p} (1 - \bar{p})}{n}}$  /. n -> 80;

Usamos la funcion  $z[c]$  antes definida para obtener los coeficientes  $Z$ , para  $\alpha = 0.05$

In[23]:= **{LimiteSuperior , LimiteInferior } = { $\bar{p} + z[0.975]$  intervalo ,  $\bar{p} - z[0.975]$  intervalo }**

Out[23]= {0.273029, 0.101971}

En resumen,  $0.1020 \leq p \leq 0.2730$

## Ejercicios propuestos

El resultado de los ensayos para verificar la resistencia a la rotura, en newtons, de dos muestras de cable procedentes de dos fabricantes A y B son los siguientes:

```
In[24]:= muestraA =
      {2.297, 2.582, 1.949, 2.362, 2.040, 2.133, 1.855, 1.986, 1.642, 2.915};
muestraB = {2.286, 2.327, 2.388, 3.172, 3.158, 2.751,
      2.222, 2.367, 2.247, 2.512, 2.104, 2.707};
```

En la resolución del ejercicio aplica los criterios y el formato establecido en la ISO 2854-1976(E)

a) ¿Se puede asumir que cada muestra procede de una población normal?

### Resolución

b) El fabricante A dice que su proceso produce cables con una resistencia media  $m_A = 2.40$  newtons y una  $\sigma_A = 0.3315$ . El test se aplicará a una muestra de tamaño  $n_A = 10$ . ¿Puede asumirse esta hipótesis? (Utilícese un nivel de significación  $\alpha = 0.05$ )

Resolución

```
In[26]:=  $\bar{x}_A = \text{Mean}[muestraA]$ 
```

```
Out[26]= 2.1761
```

```
In[27]:=  $c = 1 - \alpha / 2 /. \{\alpha \rightarrow 0.05\}$ 
```

```
Out[27]= 0.975
```

Calculamos, separadamente, primero el término de la derecha de la ec(1) y a continuación del de la izquierda, y aplicamos (1)

```
In[28]:=  $l1 = z[c] \frac{\sigma}{\sqrt{n}} /. \{\sigma \rightarrow 0.3315, n \rightarrow 10\}$ 
```

```
Out[28]= 0.205462
```

```
In[29]:=  $l2 = \text{Abs}[\bar{x}_A - m_A] /. m_A \rightarrow 2.40$ 
```

```
Out[29]= 0.2239
```

```
In[30]:=  $l2 \geq l1$ 
```

```
Out[30]= True
```

Por tanto, se concluye que hipótesis  $H_0: \mu = m_0$  se rechaza

### Ejemplos adicionales

c) Repite el apartado anterior utilizando la desviación standard de la muestra A,  $s_A$

d) El fabricante B indica que su proceso tiene una  $\sigma_B = 0.3112$ , y que para determinar la media toma una muestra de tamaño  $n_B = 12$ . ¿Puede asumirse que sus cables presentan una resistencia media a la rotura similar al fabricante A.

e) Repite el apartado anterior utilizando las desviaciones standards de la muestra A,  $s_A$ , y de la muestra B,  $s_B$ .

- f) Estima el intervalo central para la diferencia entre las medias de A y B, con un 95% de confianza. Asume que  $\sigma_A$  y  $\sigma_B$  son las proporcionadas por los fabricantes.
- g) Repite el apartado anterior utilizando las desviaciones standards de la muestra A,  $s_A$ , y de la muestra B,  $s_B$  y asumiendo que  $\sigma_A = \sigma_B$ .
- h) La especificación para la aceptación de los cables especifica que la varianza de la resistencia a la rotura no debe exceder  $\sigma_0^2 = 0.0900$ . ¿Puede asumirse, a partir de las muestras A y B, que los fabricantes cumplen con este requisito?.
- i) A partir de las muestras A y B, estima el intervalo central , con un 95% de confianza, para  $\sigma_A$  y  $\sigma_B$ .
- j) A partir de las muestras A y B, puede asumirse que las varianzas de ambas poblaciones son iguales  $\sigma_A = \sigma_B$ .
- k) A partir de las muestras A y B, estima el intervalo central , con un 95% de confianza, para  $\sigma_A/\sigma_B$ .

## El paquete Intervalos

En este apartado se describe el paquete Intervalos que permite calcular intervalos de confianza de la media y los de tolerancia de poblaciones, así como el tamaño muestral.


```
In[31]:= Needs ["Estadística`ControlCalidad`"]
ControlCalidad, version 1.1 2015-05-19
```

```
In[32]:= ? "Estadística`ControlCalidad`*"
```

▼ Estadística`ControlCalidad`

g1	g2	limite- Bilat- eral	limite- Unil- ater- al	p1	ProbA- lfa	sizeS- amp- le	t1	z1
----	----	---------------------------	---------------------------------	----	---------------	----------------------	----	----

Algunas de las funciones del paquete intervalo pueden ejecutarse directamente en un navegador web: <http://www3.enusa.es/webMathematica/Estadistica/estadistica.htm>



## Intervalos de confianza de la media para varianza conocida

Sea  $\bar{y}$  la media de cierta medida realizada a una muestra procedente de una población de la que se conoce su varianza que es  $\sigma^2$ . Llamamos intervalo de confianza para  $\bar{y}$  con nivel de confianza  $(1 - \alpha)$  aquel que tiene una probabilidad de  $(1 - \alpha)100\%$  de contener la verdadera media  $\mu$ .

### Límite unilateral inferior

$$Y_p = \bar{y} - \frac{z(1 - \alpha)}{\sqrt{n}} \sigma$$

### Límite unilateral superior

$$Y_p = \bar{y} + \frac{z(1 - \alpha)}{\sqrt{n}} \sigma$$

### Límite bilateral inferior

$$Y_p = \bar{y} - \frac{z(1 - \alpha / 2)}{\sqrt{n}} \sigma$$

### Límite bilateral superior

$$Y_p = \bar{y} + \frac{z(1 - \alpha / 2)}{\sqrt{n}} \sigma$$

Calcular los intervalos de confianza unilaterales y bilaterales para:  $\bar{y} = 50$ ,  $\sigma = 3$ ,  $n = 30$ , y  $\alpha = 0.10$ .

## Cálculo del intervalo de confianza en muestras de poblaciones normales con varianza conocida

La siguiente función calcula el Límite Superior (LS) y el Límite inferior (LI) del intervalo de confianza de la media de una población normal de varianza conocida.

Entre n:	<input type="text" value="30"/>	Entre alfa:	<input type="text" value="0.05"/>
Entre la media muestral:	<input type="text" value="10.34"/>	Entre la desviación típica poblacional:	<input type="text" value="1.23"/>
<input type="button" value="Evaluar"/>			

▼ results

□

El resultado muestra LS y el LI para el caso bilateral y unilateral

**Nota:** [Pulse aquí](#) para obtener información de ayuda

## Intervalos de confianza de la media para varianza desconocida

Sea  $\bar{y}$  la media de cierta medida realizada a una muestra procedente de una población de la que se no conoce su varianza, pero si la varianza muestral

Si desconocemos la varianza de la población utilizaremos la distribución  $t$  que la que se verifica  $t = (\bar{y} - \mu)/(s/\sqrt{n})$ , donde  $s$  es la desviación estándar muestral, con la que se obtiene los siguientes límites para los intervalos

### Límite unilateral inferior

$$Y_p = \bar{y} - \frac{t(n-1, 1-\alpha)}{\sqrt{n}} s$$

### Límite unilateral superior

$$Y_p = \bar{y} + \frac{t(n-1, 1-\alpha)}{\sqrt{n}} s$$

### Límite bilateral inferior

$$Y_p = \bar{y} - \frac{t(n-1, 1-\alpha/2)}{\sqrt{n}} s$$

### Límite bilateral superior

$$Y_p = \bar{y} + \frac{t(n-1, 1-\alpha/2)}{\sqrt{n}} s$$

## Cálculo del intervalo de confianza en muestras normales con varianza desconocida

La siguiente función calcula el Limite Superior (LS) y el Limite inferior (LI) del intervalo de confianza de una población normal de varianza desconocida.

Entre n:	<input type="text" value="30"/>	Entre alfa:	<input type="text" value="0.05"/>
Entre la media muestral:	<input type="text" value="10.34"/>	Entre la desviacion tipica muestral:	<input type="text" value="1.2"/>
<input type="button" value="Evaluar"/>			

*results* \_\_\_\_\_

El resultado muestra LS y el LI para el caso bilateral y unilateral

**Nota:** [Pulse aquí](#) para obtener información de ayuda

# Cálculo de intervalos de tolerancia en poblaciones normales

## Conceptos

En control de calidad a veces es necesario definir el intervalo de tolerancia (no confundir con intervalo de confianza).

Consideremos una población de la que tomamos una muestra de tamaño  $n$  en la que medimos cierta característica  $y$  (diámetro, densidad, peso, etc.). Calculamos su media  $\bar{y}$  y su desviación estándar  $s$ . El cliente puede requerir que dicha característica esté dentro de un intervalo de tolerancia.

Definimos el  $100p$ -ésimo percentil al valor  $Y_p$  por debajo del cual está el  $100p\%$  de la población, o, lo que es equivalente, aquel valor para el que las observaciones de muestra aleatoria de la población cae con una probabilidad  $p$ . En ocasiones nos interesa estimar el valor de  $Y_p$  asociándole un intervalo de confianza,  $(1 - \alpha) 100\%$ . Ejemplo: Deseamos calcular el valor por debajo del cual está el 95% de la población con un nivel de confianza del 95%. Problemas similares consisten en calcular límites centrales dentro de los cuales está el  $100p\%$  de la población, y límites inferiores por encima del cual está  $100p\%$  de la población. Asimismo un límite superior de confianza  $(1 - \alpha) 100\%$  para el percentil  $100p$ -ésimo es equivalente al límite superior de tolerancia por debajo del cual está al menos una proporción  $p$  de la población con una probabilidad  $1 - \alpha$ . Una interpretación similar cabe del límite inferior de tolerancia.

Las expresiones específicas para obtener los límites de tolerancia  $Y_p$  son las siguientes ([requiere que la población sea normal](#))

### Límite unilateral inferior

$$Y_p = \bar{y} - \frac{t'(n-1, -z(p) \sqrt{n}; 1-\alpha)}{\sqrt{n}} s$$

### Límite unilateral superior

$$Y_p = \bar{y} + \frac{t'(n-1, z(p) \sqrt{n}; 1-\alpha)}{\sqrt{n}} s$$

### Límite bilateral inferior

$$Y_p = \bar{y} - \frac{t'(n-1, -z(p) \sqrt{n}; 1 - \frac{\alpha}{2})}{\sqrt{n}} s$$


### Límite bilateral superior

$$Y_p = \bar{y} + \frac{t'(n-1, z(p) \sqrt{n}; 1 - \frac{\alpha}{2})}{\sqrt{n}} s$$


donde  $t'$  es la distribución  $t$  - Student no central

`NoncentralStudentTDistribution [ $\nu, \delta$ ]` a noncentral Student  $t$  con  $\nu$  grados de libertad y un parámetro de no centralidad  $\delta$ .

```
In[86]= Plot[
  Evaluate@Table[PDF[NoncentralStudentTDistribution[25,  $\delta$ ], x], { $\delta$ , {-2, 0, 3}},
  {x, -6, 8}, Filling -> Axis]
```



```
In[87]= Plot[
  Evaluate@Table[CDF[NoncentralStudentTDistribution[25,  $\delta$ ], x], { $\delta$ , {-2, 0, 3}},
  {x, -6, 8}, Filling -> Axis]
```



## Calculo de $k_{n, \alpha, p}$ (método exacto)

$$k_{n, \alpha, p} = \frac{t'(n-1, z(p) \sqrt{n}; 1-\alpha)}{\sqrt{n}}$$

De forma exacta puede calcularse aplicando:

```
In[88]= K1Exacto[n_,  $\alpha$ _, p_] :=
  Module[{z}, z = Quantile[NormalDistribution[0, 1], p];
  (1/Sqrt[n]) * Quantile[NoncentralStudentTDistribution[n - 1, z * Sqrt[n]],
  1 -  $\alpha$ ]
```

Ejemplo: La  $k(95/95)$  unilateral para una muestra de tamaño 2 a 10 son

```
In[89]= Table[{r, K1Exacto[r, 0.05, 0.95]}, {r, 2, 10}]
```

```
Out[89]= {{2, 26.2597}, {3, 7.6559}, {4, 5.14387}, {5, 4.20268},
  {6, 3.70768}, {7, 3.39947}, {8, 3.18729}, {9, 3.03124}, {10, 2.91096}}
```

Los valores son practicamente identicos a los encontrados en las tablas consultadas

## Calculo de $k_{n,\alpha,p}$ (Método aproximado)

El método anterior requiere un consumo eleva de recursos de ordenador que lo hace poco adecuado cuando el valor  $n$  empieza a ser elevado ( $n > 10$ ). Una aproximación excelente a (13) puede obtenerse para el caso bilateral, que es el mas complicado aplicando la siguiente aproximación

$$k_{n,\alpha,p} \approx z \left[ (1+p) / 2 \right] \left( \frac{(n-1)}{\chi^2(n-1; \alpha)} \right)^{1/2} \left( 1 + \frac{1}{2n} \right)$$

Expresado en el lenguaje del *Mathematica* es

```
In[90]:= g2[n_, α_, p_] := Module[{z, ji2}, z = Quantile[NormalDistribution[0, 1], (1+p)/2];
      ji2 = Quantile[ChiSquareDistribution[n-1], α];
      z Sqrt[(n-1)/ji2 (1 + 1/(2n))]
```

Ejemplo: La  $k(95/95)$  bilateral para una muestra de tamaño  $n = 50$  y otra para  $n = 1000$  son

```
In[91]:= g2[50, 0.05, 0.95]
```

```
Out[91]= 2.37889
```

```
In[92]:= g2[1000, 0.05, 0.95]
```

```
Out[92]= 2.03608
```

Estos valores muestran una excelente aproximación para los encontrados en tablas

Tambien podemos aplicar una aproximación para el caso unilateral cuando el el valor  $n$  empieza a ser elevado ( $n > 10$ ).

$$k_{n,\alpha,p} = \frac{t'(n-1, z(p) \sqrt{n}; 1-\alpha)}{\sqrt{n}} \approx \left( z(p) + [z^2(p) - a b]^{1/2} \right) / a$$

donde

$$a = 1 - [z(1-\alpha)]^2 / [2(n-1)]$$

$$b = [z(p)]^2 - [z(1-\alpha)]^2 / n$$

Expresado en el lenguaje del *Mathematica* es

```
In[93]:= g1[n_, α_, p_] := Module[{zp, za, a, b}, zp = Quantile[NormalDistribution[0, 1], p];
      za = Quantile[NormalDistribution[0, 1], 1-α];
      a = 1 - (za^2)/(2(n-1));
      b = zp^2 - (za^2)/n;
      (zp + Sqrt[zp^2 - a b]) / a]
```

```
In[94]= g1[10, 0.05, 0.95]
```

```
Out[94]= 2.8748
```

Los aproximación aumenta con el tamaño de la muestras: Ejemplo: Calcular la k(95/95) unilateral para n={10, 100, de 10 en 10} :

```
In[95]= Table[{n, g1[n, 0.05, 0.95]}, {n, 10, 100, 10}]
```

```
Out[95]= {{10, 2.8748}, {20, 2.37835}, {30, 2.20851}, {40, 2.11721}, {50, 2.05849},  
          {60, 2.01681}, {70, 1.98533}, {80, 1.9605}, {90, 1.94029}, {100, 1.92344}}
```

## Criterios para determinar si una muestra está dentro del intervalo de tolerancia para un P y alfa dados

Dado un intervalo de tolerancia definido por los límites superior e inferior (LS, LI) pretendemos saber si una muestra de media  $\bar{x}$  y desviación estandar  $s$  está comprendida en el intervalo de tolerancia para un P dado

Conocidos los LS e LI de aceptación, y los parametros muestrales  $\bar{x}$ ,  $s$  y  $n$ , se trata de calcular  $p$  fijado  $\alpha$  y ver si este  $p$  es mayor o igual que un P dado. Para ello:

a) Hacemos  $Y_p = LS$  y  $Y_p = LI$  en (10) y obtenemos

$$g1[n, \text{alfa}, pS] = \frac{LS - \bar{x}}{s} \text{ y de aquí } pS \left[ g1[n, \text{alfa}], \frac{LS - \bar{x}}{s} \right] = p_{LS}$$

$$g1[n, \text{alfa}, 1 - pI] = \frac{\bar{x} - LI}{s} \text{ y de aquí } pI \left[ g1[n, \text{alfa}], \frac{\bar{x} - LI}{s} \right] = p_{LI}$$

donde  $p_{LS}$  indica la proporción de la población comprendida entre LS y 0 y  $p_{LI}$  indica la proporción de la población comprendida entre LI y 0 (estrictamente en vez de 0 es  $-\infty$ , pero asumimos que la variable  $x$  sólo toma valores positivos).

b) La población será aceptada si se verifica que  $p_{LS} - p_{LI} = p \geq P$ , siendo  $P$  la proporción de la población que se considera aceptable.

Creamos una sentencia que nos automatice el anterior proceso (para  $P = 0.95$  y  $\text{alfa} = 0.05$ ), donde  $\text{mean}$  es la media de la muestra  $\bar{x}$ ,  $\text{size}$  su tamaño  $n$ ,  $\text{uL}$  le LS,  $\text{uL}$  el LI y  $\text{sigma}$  la  $s$  de la muestra

## Aceptacion/rechazo de la poblacion (normal) muestra

La siguiente función calcula si una población es aceptable o rechazable dados los límites superior (LS) e inferior (LI) de aceptación. Para ello se parte de una muestra, procedente de una población normal, de un tamaño  $n$ , con una media  $\bar{x}$  y una desviación típica  $s$  dadas. El cálculo se hace para un nivel de confianza  $1 - \alpha$  y una proporción  $P$  de aceptación.

Tamaño muestral:	<input type="text" value="30"/>	Alfa (nivel de confianza 1 - alfa):	<input type="text" value="0.05"/>	P (Proporción de aceptación):	<input type="text" value="0.95"/>
Media muestral:	<input type="text" value="10.34"/>	Desviación típica muestral:	<input type="text" value="1.23"/>	Límite superior de aceptación:	<input type="text" value="12.5"/>
		Límite inferior de aceptación:	<input type="text" value="7.4"/>		
<input type="button" value="Evaluar"/>					

*results*

El resultado corresponde al caso unilateral

**Nota:** [Pulse aquí](#) para obtener información de ayuda

## Criterios para determinar si fijado alfa, el tamaño muestral y el valor de K que porcentaje de la poblacion está dentro del intervalo de tolerancia

### Coeficiente de tolerancia: Cálculo de P en $K1(n, \alpha, P) = Ka$

Dado el factor unilateral de tolerancia  $K1(n, \alpha, P) = Ka$ , donde n (número de datos), alfa (el nivel de confianza) y a (valor del coeficiente) son conocidos, la función calcular el valor de P (Probabilidad).

Entre n:  Entre alfa:

Entre Ka:

*↙ results*

El resultado muestra P fijado n y alfa.

**Nota:** [Pulse aquí](#) para obtener información de ayuda

2.	2.2	2.12
0.929747	0.949279	0.942074

## Dato el tamaño muestral, el nivel de confianza y la fracción defectuosa calcular el tamaño muestral para un muestreo simple con cero rechazos

### Tamaño muestral en funcion de N, p y f

Dado N, alfa (el nivel de confianza) y f (fracción de defectuosas) son conocidos, la función calcula el valor de n (tamaño de la muestra), para un muestreo simple con cero rechazos. La entrada permite introducir para N varios valores.

Entre N. {50, 200, 500, 1000, 2000}	Entre alfa. 0.05	Entre f. 0.01
<input type="button" value="Evaluar"/>		

resulta

El resultado muestra n fijado f, N y alfa.

**Nota:** [Pulse aquí](#) para obtener información de ayuda

El problema mas frecuente en muestreo es determinar el tamaño de la muestra y el número de uds. no conformes en la muestra. Vamos a describir como realizarlo en el caso de muestreos simples.

Sea una población de tamaño  $N$ , del que desconocemos el número de uds defectuosas. La probabilidad  $P_a$  de que haya  $r$  o menos defectuosas nos viene dada por la distribución hipergeométrica.

$$P_a = \sum_{x=0}^r \frac{\binom{D}{x} \binom{N-D}{n-x}}{\binom{N}{n}}$$

donde

$D$  Número de piezas defectuosas en el lote (desconocidas).

$f$  Fracción de uds defectuosas:  $f = D/N$ ,  $f$  es desconocida, se toma como valor la fracción máxima,  $p_A$ , de la población que admitiríamos que este formada por uds fuera de los límites de tolerancia.

$\alpha$  = nivel de significación (Probabilidad de cometer un error de tipo I que estamos dispuesto a asumir).

$n$  = tamaño muestral

En el caso particular de que el criterio de aceptación sea  $c = 0$

$$P_a = \frac{\binom{(1-f)N}{n}}{\binom{N}{n}}, \text{ entonces fijado } P_a \text{ podemos calcular } n$$

## Test de normalidad

EHE incluye un conjunto de test de normalidad. Es de destacar el test de D' Agostino que aplica a muestras con n grande

```
In[33]:= Needs ["Estadistica`NormalityTests`"]
```

```
In[34]:= ? "Estadistica`NormalityTests`*"
```

▼ Estadistica`NormalityTests`

DAgostinoP- earsonKS- quareTest	KurtosisM	NormalityTe- sts	Omnibus	Significance	Urzua
JarqueBera	multinormal- TestStatist- ic	normalityTe- stStatistic	Residuals	SkewnessM	

## Ejemplos: Normality test: JarqueBera, Urzua, DAgostino

testdata1 is a vector of uniformly distributed random numbers between zero and one; testdata2 is a vector of numbers drawn from the Normal(3,1) distribution. Therefore the tests should reject normality for testdata1 and not reject for testdata2.

To not reject the normality of the data Crit Stat  $\leq$  Crit. Value

```
In[104]:= testdata1 = RandomReal[{0, 1}, 1000];
```

```
In[105]:= testdata2 = RandomReal[NormalDistribution[3, 1], 1000];
```

```
In[106]:= normalityTestStatistic[testdata1, Method -> JarqueBera, Significance -> 0.05]
```

```
Out[106]//TableForm=
```

Test Stat	N for crit	Crit.Value at 0.05
57.1959	1000.	5.99146

```
In[107]:= normalityTestStatistic[testdata2, Method -> JarqueBera, Significance -> 0.05]
```

```
Out[107]//TableForm=
```

Test Stat	N for crit	Crit.Value at 0.05
1.27298	1000.	5.99146

```
In[108]:= normalityTestStatistic[testdata2, Method -> Urzua, Significance -> 0.01]
```

```
Out[108]//TableForm=
```

Test Stat	N for crit	Crit.Value at 0.01
1.34301	1000.	9.21034

Using DAgostinoPearsonKSquareTest the Normally distributed data should tend to have pvalues that are not too small. At least should be required PValue  $\geq 0.05$ .

```
In[109]:= DAgostinoPearsonKSquareTest[testdata1]
```

```
Out[109]= {KSquareStatistic -> 592.314, PValue -> 0.}
```

```
In[110]:= DAgostinoPearsonKSquareTest[testdata2]
```

```
Out[110]= {KSquareStatistic -> 1.40895, PValue -> 0.494368}
```

## Ejemplos: Multinormality Test : Omnibus, KurtosisM, SkewnessM

We will simulate a MultinormalDistribution

```
In[35]:= mu = {2, 3, 4};
```

```
In[36]:= sigma = {{1, 1/2, 1/3}, {1/2, 1/3, 1/4}, {1/3, 1/4, 1/5}};
```

```
In[37]:= multi1 = RandomReal[MultinormalDistribution[mu, sigma], 100];
```

```
In[38]:= multi = Round[100 * multi1];
```

To no reject the normality of the data Crit Stat  $\leq$  Crit. Value

```
In[39]:= multinormalTestStatistic[Transpose[multi],
  Method -> Automatic, Significance -> 0.9]
```

```
Out[39]/TableForm=
Automatic Test Stat N for crit Crit.Value at 0.9
4.03947 100 11.12
```

```
In[40]:= multinormalTestStatistic[Transpose[multi], Method -> Omnibus, Significance -> 0.9]
```

```
Out[40]/TableForm=
Omnibus Test Stat N for crit Crit.Value at 0.9
4.03947 100 11.12
```

```
In[41]:= multinormalTestStatistic[Transpose[multi],
  Method -> KurtosisM, Significance -> 0.9]
```

```
Out[41]/TableForm=
KurtosisM Test Stat N for crit Crit.Value at 0.9
2.68524 100 6.07
```

```
In[42]:= multinormalTestStatistic[Transpose[multi],
  Method -> SkewnessM, Significance -> 0.9]
```

```
Out[42]/TableForm=
SkewnessM Test Stat N for crit Crit.Value at 0.9
1.35423 100 6.27
```

Ejemplo inclinación cabezales

```
In[43]:= inclinacion1 = {{2.4, 0.3}, {1.36, 0.48}, {0.48, 1.94}, {0.6, 0.38}, {1.2, 0.15},
  {0.56, 1.15}, {0.5, 0.2}, {2.08, 0.62}, {0.5, 0.7}, {0.62, -0.5}, {0.88, 0.56},
  {0.6, -0.7}, {0.68, 0.18}, {1.6, 0.68}, {1.48, 0.18}, {0.68, 0.4},
  {0.58, 1.48}, {0.2, 0.52}, {0.34, 0.42}, {0.56, 0.22}, {1.74, 0.32},
  {0.16, 0.58}, {1.84, 0.22}, {0.86, 0.24}, {0.4, -0.16}, {1.12, 0.64},
  {0.26, 0.3}, {0.18, 0.22}, {0.88, 0.28}, {1.6, 0.2}, {0.5, -0.52},
  {1.5, -0.6}, {0.92, 0.16}, {1.7, -0.6}, {0.7, 0.6}, {0.84, 0.18},
  {0.32, 0.14}, {0.6, -0.4}, {0.2, -0.3}, {2.54, 0.38}, {0.4, 0.5},
  {1.5, 0.48}, {0.72, 0.14}, {1.54, 0.34}, {2.52, -0.18}, {2.04, 0.44},
  {0.54, 1.74}, {1.5, -1.2}, {0.88, 0.18}, {1.74, 0.72}, {0.4, 0.5},
  {1.58, 0.64}, {0.52, 0.6}, {0.65, 0.52}, {2.6, -1.}, {2.22, 0.44}};
```

```
In[44]:= inclinacion2 = {{0.9, 2.54}, {-0.4, 2.}, {1.5, 0.32}, {0.86, 2.04}, {1.38, 2.34},
    {1., 1.4}, {1.28, 2.54}, {0.6, 0.7}, {0.88, 2.18}, {0.75, -0.7},
    {1.44, 2.12}, {1.62, 1.54}, {0.54, 0.76}, {0.64, 0.7}, {1.94, 2.12},
    {1.9, 1.9}, {1.64, 1.1}, {1.4, 1.7}, {1.28, 2.08}, {1.1, 1.42}, {1.68, 1.2},
    {1.68, 1.2}, {3.26, -0.38}, {2.1, 2.3}, {1.3, 2.2}, {0.68, 2.54},
    {0.68, 0.74}, {1.52, 2.12}, {2.1, -3.04}, {-0.5, 2.}, {0.9, 2.8},
    {1.12, 3.02}, {1.32, 2.98}, {1.1, 1.4}, {1.62, 3.12}, {2.3, 1.2}};
```

```
In[45]:= multinormalTestStatistic[Transpose[inclinacion1],
    Method -> Automatic, Significance -> 0.9]
```

Out[45]/TableForm=

Automatic	Test Stat	N for crit	Crit.Value at 0.9
12.3733		50	7.83

```
In[46]:= multinormalTestStatistic[Transpose[inclinacion1],
    Method -> Omnibus, Significance -> 0.9]
```

Out[46]/TableForm=

Omnibus	Test Stat	N for crit	Crit.Value at 0.9
12.3733		50	7.83

```
In[47]:= multinormalTestStatistic[Transpose[inclinacion1],
    Method -> SkewnessM, Significance -> 0.9]
```

Out[47]/TableForm=

SkewnessM	Test Stat	N for crit	Crit.Value at 0.9
5.32233		50	4.64

```
In[48]:= multinormalTestStatistic[Transpose[inclinacion1],
    Method -> KurtosisM, Significance -> 0.9]
```

Out[48]/TableForm=

KurtosisM	Test Stat	N for crit	Crit.Value at 0.9
7.05093		50	4.07

```
In[49]:= multinormalTestStatistic[Transpose[inclinacion2],
    Method -> Automatic, Significance -> 0.9]
```

Out[49]/TableForm=

Automatic	Test Stat	N for crit	Crit.Value at 0.9
66.7978		20	8.39

```
In[50]:= multinormalTestStatistic[Transpose[inclinacion2],
    Method -> Omnibus, Significance -> 0.9]
```

Out[50]/TableForm=

Omnibus	Test Stat	N for crit	Crit.Value at 0.9
66.7978		20	8.39

```
In[51]:= multinormalTestStatistic[Transpose[inclinacion2],
    Method -> SkewnessM, Significance -> 0.9]
```

Out[51]/TableForm=

SkewnessM	Test Stat	N for crit	Crit.Value at 0.9
20.6641		20	4.79

```
In[52]:= multinormalTestStatistic[Transpose[inclinacion2],
    Method -> KurtosisM, Significance -> 0.9]
```

Out[52]/TableForm=

KurtosisM	Test Stat	N for crit	Crit.Value at 0.9
46.1337		20	4.22