



# Tests

## Modelado y Análisis de Redes de Telecomunicaciones



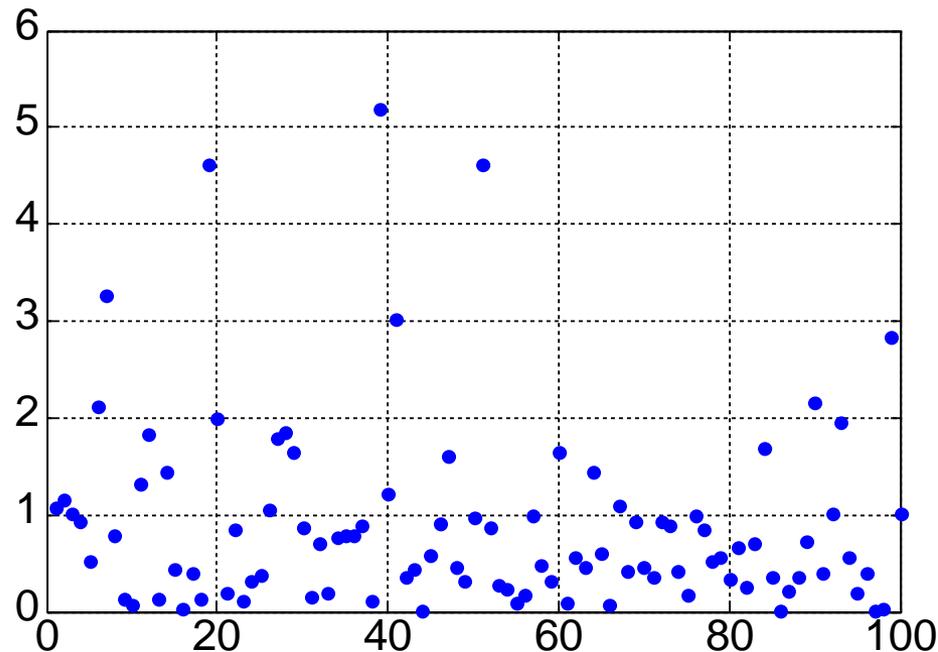
UNIVERSIDAD  
DE LA REPUBLICA  
URUGUAY



# Tests



- Los tests son una herramienta para contestar preguntas del tipo:
  - ¿Mis datos son la realización de una V.A. normal?
  - ¿Mis datos son la realización de una V.A. con media nula?

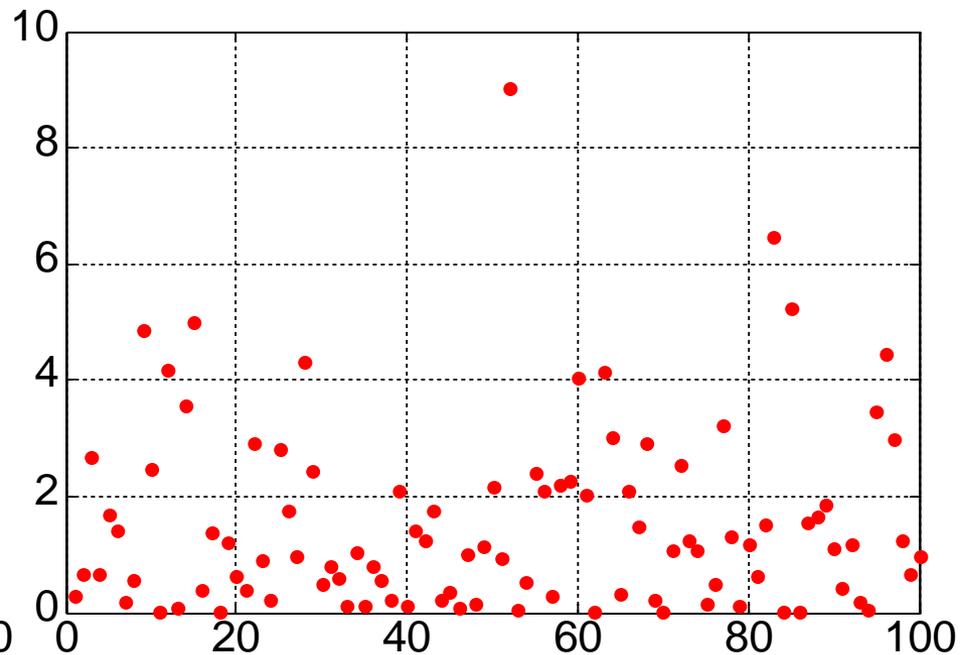
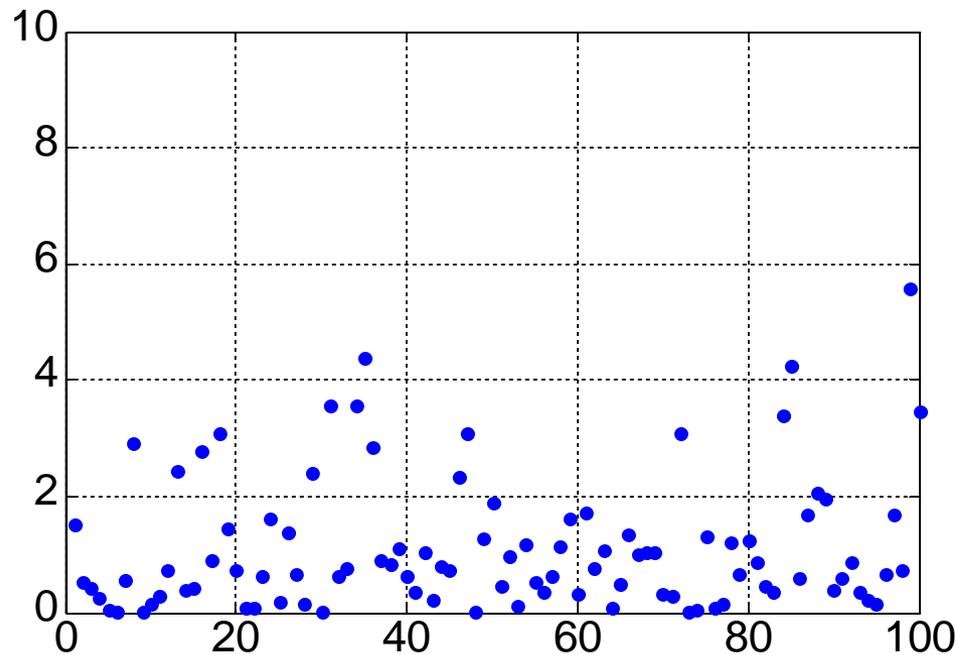




# Tests



- Los tests son una herramienta para contestar preguntas del tipo:
  - ¿Estos sets de datos tiene la misma distribución?
  - ¿La misma media?

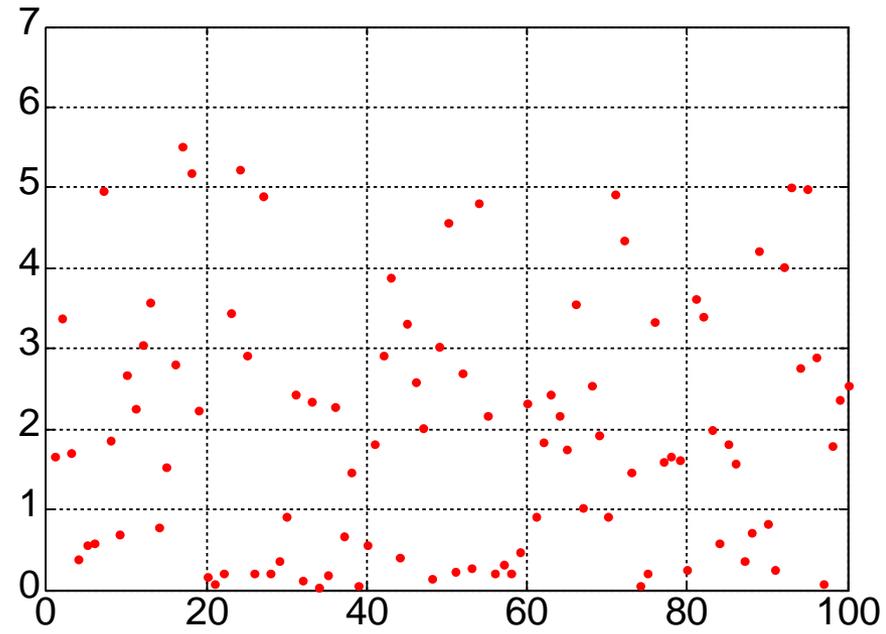
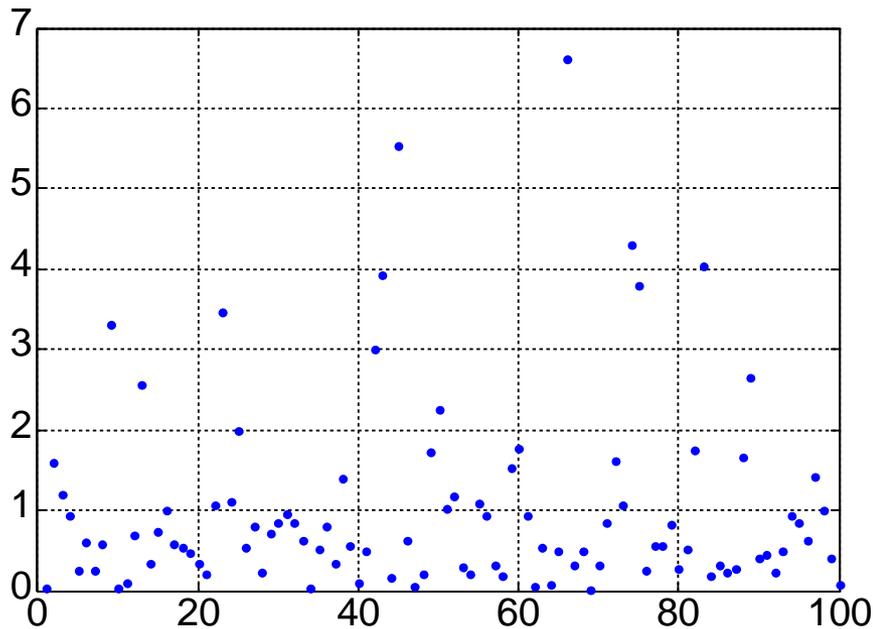




# Tests



- Con lo que vimos hasta ahora hay ciertos casos que ya sabemos contestar...
- **Ejemplo:** comparación de dos procesadores
  - ¿cuál es más rápido?

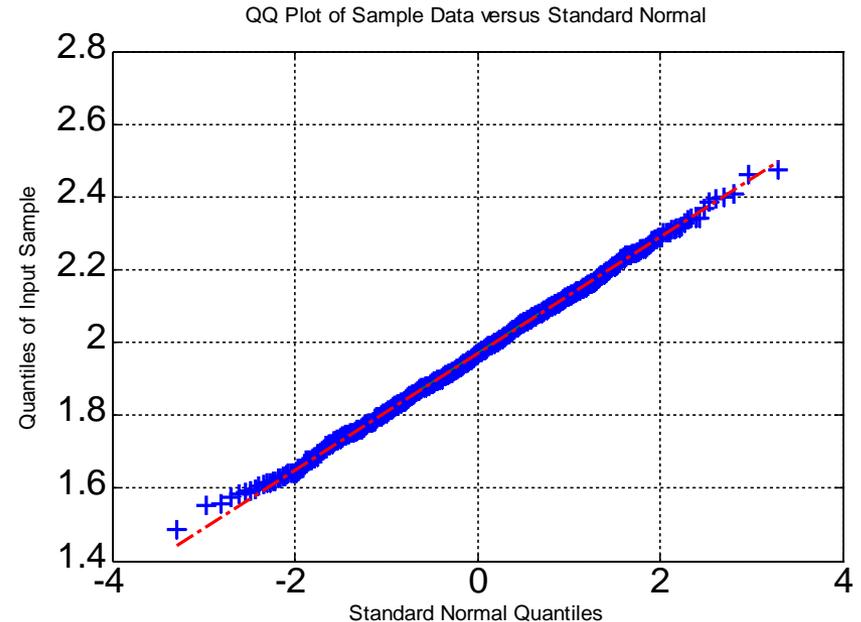
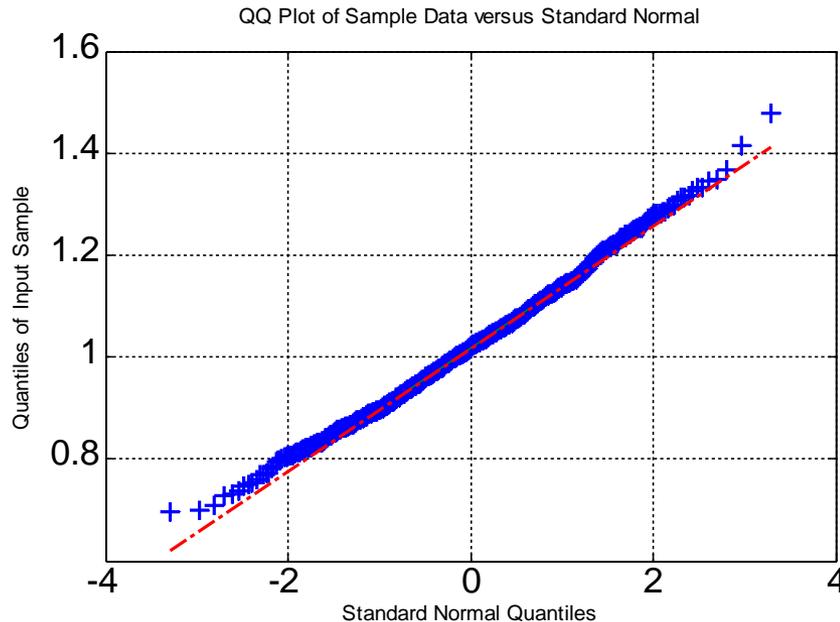




# Tests



## ■ QQPlot de la la distribución del promedio (con bootstrap)



## ■ Podemos estimar un intervalo de confianza para la esperanza:

- I. de C. = [0.78958, 1.2586]
- I. de C. = [1.6665, 2.2724]

## ■ Con $p=0.95$ la media del azul es menor que la del rojo (¿faltó testear algo?)





# Tests



- **Conclusión:**
  - Hay ciertos casos que no necesito entrar en la teoría de los tests, sino que basta con calcular intervalos de confianza
- ¿Qué hubiera pasado si los intervalos se solapaban?
- Hay muchas preguntas que no se pueden formular como un intervalo de confianza





# Agenda



- Neyman-Pearson
- Likelihood Ratio Tests
- ANOVA
- Resultados asintóticos
- Otros tests...



# Contexto



- ¿Qué nos interesa decidir?
  - Tenemos un montón de números  $x_1, \dots, x_n$  y sospechamos que responden a un cierto modelo
  - Nos interesaría saber si el modelo es razonablemente correcto
  - Principio de parsimonia
    - Ante la duda preferir el modelo más sencillo
- Un marco que se adapta a este contexto es el de Neyman-Pearson





# Neyman-Pearson



- La hipótesis nula y la alternativa
  - Tenemos la muestra  $x_1, \dots, x_n$  generadas por un modelo desconocido y dos hipótesis
    - $H_0$ : la hipótesis nula
    - $H_1$ : la hipótesis alternativa
  - A partir de la muestra queremos determinar cuál es la correcta
  - En el contexto de Neyman-Pearson ambas hipótesis NO son equivalentes:
    - Preferiría quedarme con  $H_0$  (i.e. rechazo  $H_0$  (acepto  $H_1$ ) sólo si la evidencia es suficientemente grande)
- En la mayoría de los tests que veremos se asumirá que el modelo desconocido se parametriza por  $\theta \in \Theta$  y quiero verificar si  $\theta$  está en un conjunto dado:

$$\begin{cases} H_0 : \theta \in \Theta_0 \in \Theta \\ H_1 : \theta \in \Theta \setminus \Theta_0 \end{cases}$$



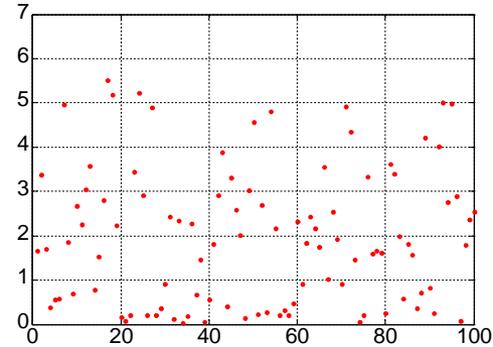
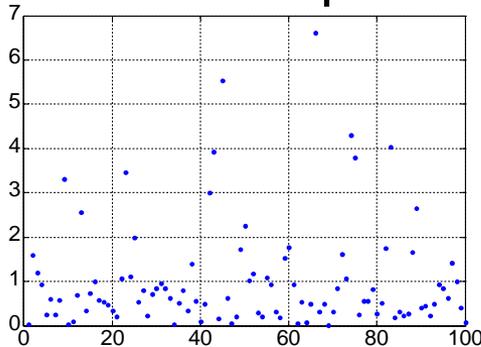


# Neyman-Pearson



## ■ **Ejemplo:** comparación de dos procesadores

- ¿cuál es más rápido?



## ■ En este caso el modelo puede ser el siguiente:

- Los dos sets de datos fueron generados cada uno por  $n$  V.A. iid (ambas con distribución exponencial) y quiero verificar si  $E\{X\} = E\{Y\}$

$$\begin{cases} H_0 : E\{X\} = E\{Y\} & (\Theta_0 = \{(F(x), F(x)) \text{ con } F(x) = 1 - e^{-\lambda x}; \lambda > 0\}) \\ H_1 : E\{X\} \neq E\{Y\} & (\Theta = \{(F(x), F(\frac{x}{k})) \text{ con } F(x) = 1 - e^{-\lambda x}; \lambda > 0, k > 0\}) \end{cases}$$



# Neyman-Pearson



- Una vez que tengo mi set de datos  $x_1, \dots, x_n$  la decisión del test es determinística
  - Hay familias de tests aleatorias que no consideraremos
- Por lo tanto, se puede definir un conjunto  $C \in \mathbb{R}^n$  de valores del vector  $(x_1, \dots, x_n)$  tales que:

$$\text{Acepto } H_0 \Leftrightarrow (x_1, \dots, x_n) \notin C$$

=>  $C$  define el test y se denomina la **región crítica** del mismo

- De aquí en adelante asumiremos que los datos son la realización de  $n$  V.A.  $X_1, \dots, X_n$  (no necesariamente iid)
- Posibles errores
  - Tipo 1 (o falso positivo): rechazar  $H_0$  cuando era correcta (su probabilidad la notaremos  $P(\text{decidir } H_1 | H_0) = P((X_1, \dots, X_n) \in C | \theta \in \Theta_0)$ )
  - Tipo 2 (o falso negativo): aceptar  $H_0$  cuando era incorrecta ( $P(\text{decidir } H_0 | H_1) = P((X_1, \dots, X_n) \in C^c | \theta \in \Theta \setminus \Theta_0)$ )





# Neyman-Pearson



## ■ Dos parámetros importantes:

- Tamaño del test:

$$\text{tamaño} = \alpha = \sup_{\theta \in \Theta_0} P(\text{decidir } H_1 | H_0)$$

En claro: la máxima probabilidad de falso positivo

- Potencia del test:

$$\text{potencia} = 1 - \beta = P(\text{decidir } H_1 | H_1) = 1 - P(\text{decidir } H_0 | H_1)$$

En claro: 1 menos la probabilidad de falso negativo en función de  $\theta \in \Theta \setminus \Theta_0$

## ■ Aquí se nos plantea el típico problema cuando existen varios indicadores a optimizar

- ¿Qué tomo como objetivo del test?
- ¿Qué es un buen test?
- POSIBLE respuesta: Criterio de Neyman-Pearson



# Neyman-Pearson



- Criterio de Neyman-Pearson
  - De aquellos tests con tamaño menor a un cierto umbral, elegir el más potente
- Criterio de Neyman-Pearson en claro:
  - Tengo bajo control la máxima probabilidad de falso positivo y hago lo mejor que puedo con la probabilidad de falso negativo
- Encaja perfectamente en el contexto que estamos trabajando
  - Quiero verificar (prefiero)  $H_0 \Rightarrow$  si el test dice  $H_1$ , queremos estar relativamente seguros que efectivamente es  $H_1$
  - ¿Si el test dice  $H_0$  que seguridad tenemos?
    - A posteriori habría que calcular la potencia del test





# Ejemplo de Test



## ■ Ejemplo ilustrativo

- Tenemos  $x_1, \dots, x_n$  que asumimos generados por  $n$  V.A. iid  $X_1, \dots, X_n$  normales (con media  $\mu$  y varianza  $\sigma^2$  desconocida)
- Queremos testear: 
$$\begin{cases} H_0 : \mu = 0 \\ H_1 : \mu > 0 \end{cases}$$

- Posible test es: si la media empírica es demasiado grande rechazamos  $H_0$

- Re-escalando nos queda la siguiente región crítica:

$$C = \left\{ (x_1, \dots, x_n) : \frac{\bar{x}}{s_n/\sqrt{n}} > c \right\}$$

- El tamaño del test resulta:

$$\begin{aligned} \alpha &= \max_{\sigma > 0} P \left( \frac{\bar{X}}{s_n/\sqrt{n}} > c \mid \mu = 0, \sigma \right) \underset{n \text{ grande}}{\approx} \max_{\sigma > 0} 1 - F_{N_{0,1}}(c) = \\ &= 1 - F_{N_{0,1}}(c) \end{aligned}$$



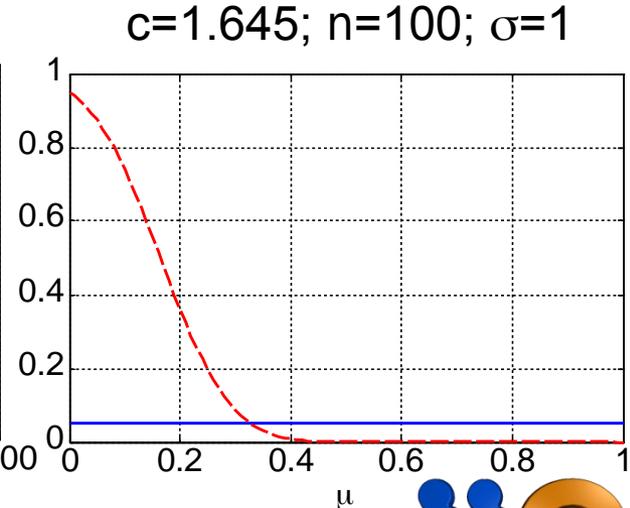
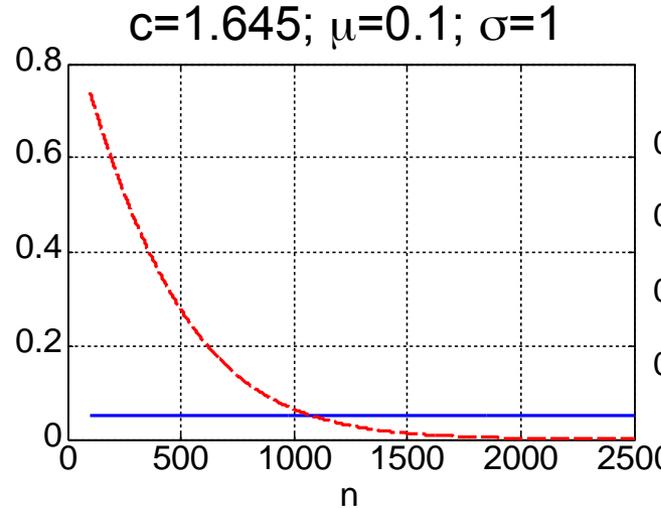
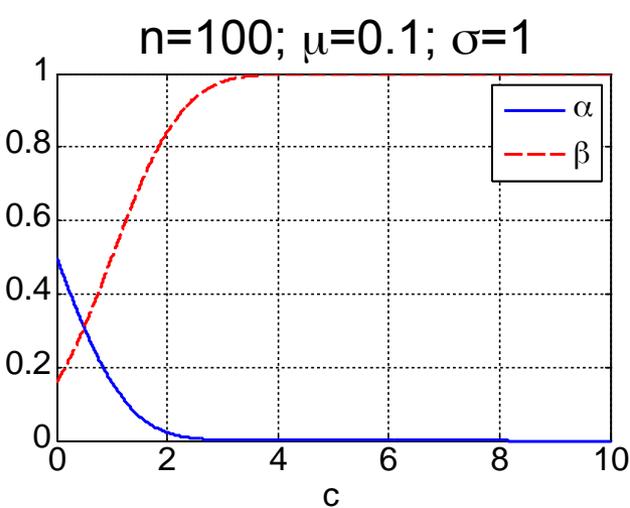
# Ejemplo de Test



## ■ Ejemplo ilustrativo (cont...)

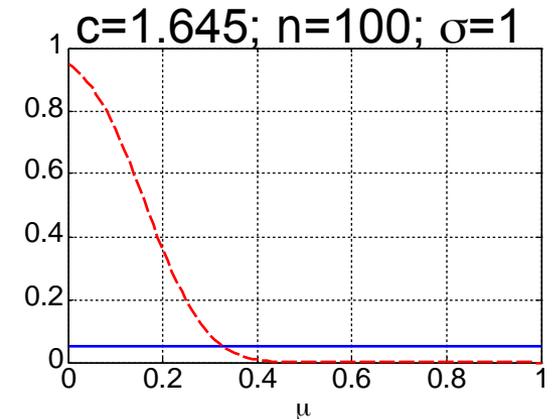
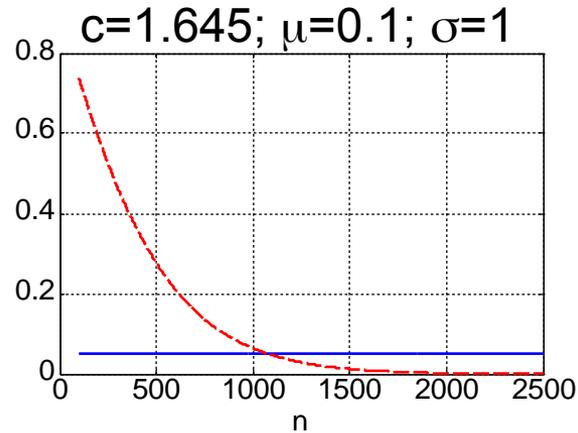
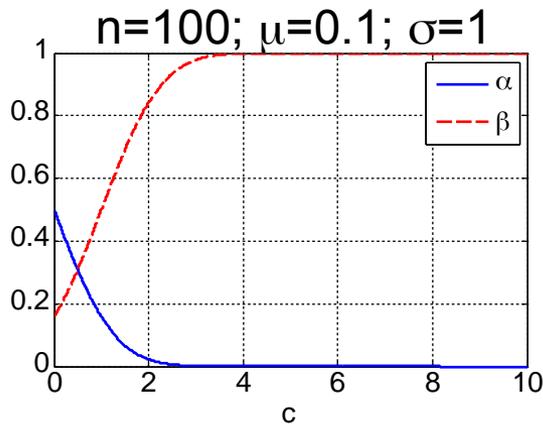
- Si quiero un tamaño de test 0.05 =>  $c=1.645$
- Potencia del test:

$$1 - \beta = P\left(\frac{\bar{X}}{s_n/\sqrt{n}} > c \mid \mu, \sigma > 0\right) =$$
$$= P\left(\frac{\bar{X} - \mu}{s_n/\sqrt{n}} > c - \frac{\mu}{s_n/\sqrt{n}} \mid \mu, \sigma > 0\right) \underset{n \text{ grande}}{\approx} 1 - F_{N_{0,1}}\left(c - \frac{\mu}{\sigma/\sqrt{n}}\right)$$





# Ejemplo de Test



## ■ Algunas conclusiones:

- Dados los datos, si la probabilidad de falso positivo decrece, la probabilidad de falso negativo crece (y viceversa)
- Cuantos más datos tengo, mejor “resolución” tiene el test
- Es posible que la probabilidad de falso positivo sea pequeña, y la probabilidad de falso negativo sea grande (e.g.  $\mu$  pequeño)
  - **REPITO**: Bajo Neyman-Pearson si el test rechaza  $H_0$  estoy bastante seguro que la decisión es la correcta, pero si acepta  $H_0$  no significa que sea verdadera, sino que **no pudo rechazarla** y hay que verificar el valor de  $\beta$  (que por lo general es muy difícil de calcular)



# p-valor

- En muchos tests la región crítica se define a partir de una cierta función  $T()$  de las observaciones  $x_1, \dots, x_n$

$$C = \{(x_1, \dots, x_n) : T(x_1, \dots, x_n) > m_0\}$$

- $T()$  se denomina estadístico del test
- Por ejemplo en nuestro test sencillo

$$T(x_1, \dots, x_n) = \frac{\bar{x}}{s_n / \sqrt{n}}$$

- Para esos casos se define el p-valor como:

$$p^*(x_1, \dots, x_n) = \sup_{\theta \in \Theta_0} P\left(T(X_1, \dots, X_n) > T(x_1, \dots, x_n) \mid \theta\right)$$

- En claro: la probabilidad de que otro set de datos (bajo  $H_0$ ) sea “más rechazable” que el que tengo ahora (con el  $\theta$  que la maximiza)
- Claramente cuanto menor  $p^*$  más razones tengo para rechazar  $H_0$





# p-valor

- Existe una relación entre  $p^*$  y el tamaño del test  $\alpha$

$$\alpha(m_0) = \sup_{\theta \in \Theta_0} P \left( T(X_1, \dots, X_n) > m_0 \mid \theta \right)$$

$$p^*(x_1, \dots, x_n) = \sup_{\theta \in \Theta_0} P \left( T(X_1, \dots, X_n) > T(x_1, \dots, x_n) \mid \theta \right)$$

- $\alpha(m_0)$  es siempre no-creciente en  $m_0$  y por lo general es decreciente

- En este último caso:

$$p^*(x_1, \dots, x_n) < \alpha \Leftrightarrow T(x_1, \dots, x_n) > m_0$$

=> **rechazo  $H_0$  si  $p^*$  es menor que el tamaño del test**

- Ejemplo: En nuestro test sencillo

$$p^*(x_1, \dots, x_n) = 1 - F_{N_0,1} \left( \frac{\bar{x}}{s_n/\sqrt{n}} \right)$$

- Por lo general los tests devuelven  $p^*$  (o una estimación) pues nos da más información que un simple aceptar/rechazar





# Un comentario....



- Atención con los tests y el resultado que devuelven
  - REPITO UNA VEZ MÁS: Que el test acepte  $H_0$  significa que la evidencia no es suficiente para rechazarla
  - Es importante la distinción entre **significado estadístico** y **significado práctico**
    - Con suficientes datos ( $n$  suficientemente grande) puedo detectar diferencias en la media de cualquier orden
    - Pero en un test como:

$$\begin{cases} H_0 : \mu = 0 \\ H_1 : \mu > 0 \end{cases}$$

existe un 0 “práctico”

- E.g. en un enlace larga distancia un retardo menor a 1ms es insignificante (significado práctico) pero con suficientes medidas puedo detectar con gran precisión medias de órdenes menores a 1ms (significado estadístico)





# Agenda



- Neyman-Pearson
- Likelihood Ratio Tests
- ANOVA
- Resultados asintóticos
- Otros tests...



# Verosimilitud



- Sea  $X$  una V.A. con densidad paramétrica en  $\theta$   $f(x, \theta)$  (el caso discreto es análogo)
- La función de verosimilitud (likelihood) se define como :

$$L(\theta, x_o) = C(x_o) f(x_o, \theta)$$

Con  $C(x_o)$  una función positiva acotada que no depende de  $\theta$

- Aunque a priori parece más de lo mismo, la idea es que la función  $L(\theta, x_o)$  como función de  $\theta$  con  $x_o$  fijo nos daría una medida de su “correctitud”
  - I.e. Si tengo una muestra de  $X$  ( $x_o$ ) y dos posibles valores de  $\theta$  ( $\theta_1$  y  $\theta_2$ ) tales que  $L(\theta_1, x_o) > L(\theta_2, x_o)$  ¿con qué valor de  $\theta$  me quedo?





# Verosimilitud

- De esta idea surge el estimador de máxima verosimilitud
  - A partir de la muestra  $x_0$  de  $X$  estimo  $\theta$  como  $\theta^*$ :

$$\theta^* = \arg \max_{\theta \in \Theta} L(\theta, x_0)$$

- Ejemplo:  $X_1, \dots, X_n$  iid  $\sim \text{Exp}(\lambda)$

$$\begin{aligned} L(\theta, x) &= \prod_{i=1}^n C(x_i) \lambda e^{-\lambda x_i} = \lambda^n e^{-\lambda \sum_{i=1}^n x_i} \prod_{i=1}^n C(x_i) \\ \Rightarrow \frac{\partial L(\theta, x)}{\partial \theta} &= \lambda^{n-1} e^{-\lambda \sum_{i=1}^n x_i} \left( n - \lambda \sum_{i=1}^n x_i \right) \prod_{i=1}^n C(x_i) \\ \Rightarrow \lambda^* &= \frac{n}{\sum_{i=1}^n x_i} = \frac{1}{\bar{x}} \end{aligned}$$





# Likelihood Ratio Tests



- La verosimilitud lógicamente también se utiliza en el contexto de tests
- Sean  $X=(X_1,\dots,X_n)$  un vector con  $n$  V.A. y sean  $f(x,\theta)$  la densidad del vector y  $x_0$  una realización
  - Imaginemos el siguiente test:

$$\begin{cases} H_0 : \theta = \theta_0 \\ H_1 : \theta = \theta_1 \end{cases}$$

- Si  $L(\theta_1,x_0)/L(\theta_0,x_0)$  es suficientemente grande es natural rechazar  $H_0$
- De esta idea surgen los denominados “likelihood ratio tests” (tests de cociente de verosimilitudes)





# Likelihood Ratio Tests



- En nuestro caso más general

$$\begin{cases} H_0 : \theta \in \Theta_0 \\ H_1 : \theta \in \Theta \setminus \Theta_0 \end{cases}$$

- Se definen las siguientes funciones:

$$l_x(\theta) = \log f_X(x, \theta)$$

$$l_x(H_0) = \sup_{\theta \in \Theta_0} l_x(\theta)$$

$$l_x(H_1) = \sup_{\theta \in \Theta} l_x(\theta)$$

- El likelihood ratio test se define por la siguiente región crítica:

$$C(x) = \{l_x(H_1) - l_x(H_0) > k\}$$

- Si  $H_0$  es verdad uno esperaría que el supremo de la verosimilitud se dé en  $\Theta_0$  ( $l_x(H_1) - l_x(H_0) \approx 0$ )
- Si no el supremo de la verosimilitud se da fuera  $\Theta_0$  ( $l_x(H_1) - l_x(H_0) > 0$ )



# Likelihood Ratio Tests



## ■ Lema de Neyman-Pearson

- Consideremos el caso sencillo  $\Theta = \{\theta_0, \theta_1\}$  y  $\Theta_0 = \{\theta_0\}$
- Sea  $C$  la región crítica definida antes con  $k$  tal que el tamaño del test resultante es  $\alpha$
- Sea  $S$  cualquier región crítica tal que el tamaño del test resultante es también  $\alpha$

$$\Rightarrow P(X \in S \mid \theta = \theta_1) \leq P(X \in C \mid \theta = \theta_1)$$

## • En claro:

- De todos los tests de tamaño  $\alpha$  el likelihood ratio test es el de mayor potencia (el de menor probabilidad de falso negativo)





# Likelihood Ratio Tests



- Volvamos a nuestro ejemplo sencillo ...
  - Tenemos  $x_1, \dots, x_n$  que asumimos generados por  $n$  V.A. iid  $X_1, \dots, X_n$  normales (con media  $\mu$  y varianza  $\sigma^2$  desconocida)
  - Queremos testear:

$$\begin{cases} H_0 : \mu = 0 \\ H_1 : \mu > 0 \end{cases}$$

- Construyamos el likelihood ratio test correspondiente:

$$l_x(\theta) = \log(f_X(x, \theta)) = \log\left(\prod_{i=1}^n f_{X_i}(x, \theta)\right) =$$
$$\log\left(\left(\frac{1}{\sqrt{2\pi\sigma^2}}\right)^n e^{-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2}\right) = -\frac{n}{2} \log(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2$$



# Likelihood Ratio Tests



- Volvamos a nuestro ejemplo sencillo ...

$$l_x(H_1) = \sup_{\mu > 0; \sigma} -\frac{n}{2} \log(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2$$

$$\Rightarrow l_x(H_1) = -\frac{n}{2} \log \left( 2\pi \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x}^+)^2 \right) - \frac{n}{2}$$

$$l_x(H_0) = \sup_{\mu=0; \sigma} -\frac{n}{2} \log(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2$$

$$\Rightarrow l_x(H_0) = -\frac{n}{2} \log \left( 2\pi \frac{1}{n} \sum_{i=1}^n x_i^2 \right) - \frac{n}{2}$$

$$\therefore l_x(H_1) - l_x(H_0) = -\frac{n}{2} \log \left( \frac{\sum_{i=1}^n (x_i - \bar{x}^+)^2}{\sum_{i=1}^n x_i^2} \right)$$



# Likelihood Ratio Tests



## ■ Volvamos a nuestro ejemplo sencillo ...

- La región crítica resulta:

$$C = \left\{ x : -\frac{n}{2} \log \left( \frac{\sum_{i=1}^n (x_i - \bar{x}^+)^2}{\sum_{i=1}^n x_i^2} \right) > k \right\} = \left\{ x : \frac{\sum_{i=1}^n (x_i - \bar{x}^+)^2}{\sum_{i=1}^n x_i^2} < k' \right\}$$

- Obs: el cociente de la región de exclusión es siempre menor o igual a 1  
=> Para que el test tenga sentido  $k'$  debe ser menor a 1  
=> Si el promedio es negativo, ya sabemos que hay que aceptar  $H_0$   
=> Asumamos que el promedio es positivo

$$C = \left\{ x : \frac{1/n \sum_{i=1}^n (x_i - \bar{x})^2}{\bar{x}^2 + 1/n \sum_{i=1}^n (x_i - \bar{x})^2} < k' \right\} = \left\{ x : \frac{\bar{x}^2}{1/n \sum_{i=1}^n (x_i - \bar{x})^2} \geq \frac{1 - k'}{k'} \right\} =$$
$$= \left\{ \frac{\bar{x}}{s_n/\sqrt{n}} \geq \sqrt{\frac{n(1 - k')}{k'}} \right\}$$

=> El test sencillo que diseñamos era un LRT!



# Test de Student



- Tenemos  $x_1, \dots, x_n$  que asumimos generados por  $n$  V.A. iid  $X_1, \dots, X_n$  normales (con media  $\mu$  y varianza  $\sigma^2$  desconocida)
- Queremos testear:

$$\begin{cases} H_0 : \mu = \mu_0 \\ H_1 : \mu \neq \mu_0 \end{cases}$$

- Dejamos como ejercicio demostrar que el likelihood ratio test en este caso es equivalente al test de student cuyo estadístico es:

$$T(x_1, \dots, x_n) = \frac{\bar{x} - \mu_0}{s_n / \sqrt{n}}$$



# Agenda



- Neyman-Pearson
- Likelihood Ratio Tests
- ANOVA
- Resultados asintóticos
- Otros tests...



# ANOVA



- Tenemos  $x_1, \dots, x_n$  que asumimos generados por  $n$  V.A. iid  $X_1, \dots, X_n$  normales (con medias  $\mu_1, \dots, \mu_n$  y varianza  $\sigma^2$  desconocida)
- Imaginemos que queremos testear alguna propiedad de las medias ( i.e.  $\theta = (\mu_1, \dots, \mu_n, \sigma)$  )
  - E.g. si son todas iguales o si hay dos grupos
- En este caso se puede usar los tests denominados ANOVA
- Otras hipótesis necesarias:
  - $\mu_1, \dots, \mu_n$  responden a un modelo lineal; i.e.  $(\mu_1, \dots, \mu_n) \in M$ , donde  $M$  es un subespacio lineal de  $R^n$
  - Queremos testear si  $(\mu_1, \dots, \mu_n) \in M_0$ , el cual a su vez es un subespacio lineal de  $M$ 
$$\begin{cases} \Theta = M \times (0, \infty) \\ \Theta_0 = M_0 \times (0, \infty) \end{cases}$$
  - $\Pi_M(x)$  es el proyector ortogonal de  $x$  en  $M$  (y  $\Pi_{M_0}(x)$  en  $M_0$ )





# ANOVA



## ■ Un ejemplo en concreto:

- Tenemos  $x_1, \dots, x_k$  e  $y_1, \dots, y_l$  que asumimos generados por  $k$  y  $l$  V.A. iid  $X_1, \dots, X_k$  y  $Y_1, \dots, Y_l$  normales (con medias  $\mu_x$  y  $\mu_y$  respectivamente y varianza  $\sigma^2$  desconocida)
- Queremos testear si  $\mu_x = \mu_y$  o no
- Entonces:
  - $M = \{(\mu_x, \dots, \mu_x, \mu_y, \dots, \mu_y), \mu_x \in \mathbb{R}, \mu_y \in \mathbb{R}\}$
  - $M_0 = \{(\mu, \dots, \mu, \mu, \dots, \mu), \mu \in \mathbb{R}\}$
  - $\Pi_M(x_1, \dots, x_k, y_1, \dots, y_l) = ((1/k)\sum x_i, \dots, (1/k)\sum x_i, (1/l)\sum y_i, \dots, (1/l)\sum y_i)$
  - $\Pi_{M_0}(x_1, \dots, x_k, y_1, \dots, y_l) = (1/(k+l)\sum x_i + 1/(k+l)\sum y_i, \dots, 1/(k+l)\sum x_i + 1/(k+l)\sum y_i)$





# ANOVA



## ■ Teorema

- Sea un test del tipo:

$$\begin{cases} H_0 : (\mu_1, \dots, \mu_n) \in M_0; \sigma > 0 \\ H_1 : (\mu_1, \dots, \mu_n) \in M \setminus M_0; \sigma > 0 \end{cases}$$

- Entonces el p-valor del likelihood ratio test resultante es:

$$p^* = 1 - F_{k-k_0, n-k}(f)$$

Donde  $F_{m,n}(x)$  es la distribución de Fisher con  $m$  y  $n$  grados de libertad

$$k = \dim M; k_0 = \dim M_0$$

$$f = \frac{SS2/(k - k_0)}{SS1/(n - k)}$$

$$SS2 = \|\hat{\mu} - \hat{\mu}_0\|^2; SS1 = \|x - \hat{\mu}\|^2$$

$$\hat{\mu}_0 = \Pi_{M_0}(x); \hat{\mu} = \Pi_M(x)$$





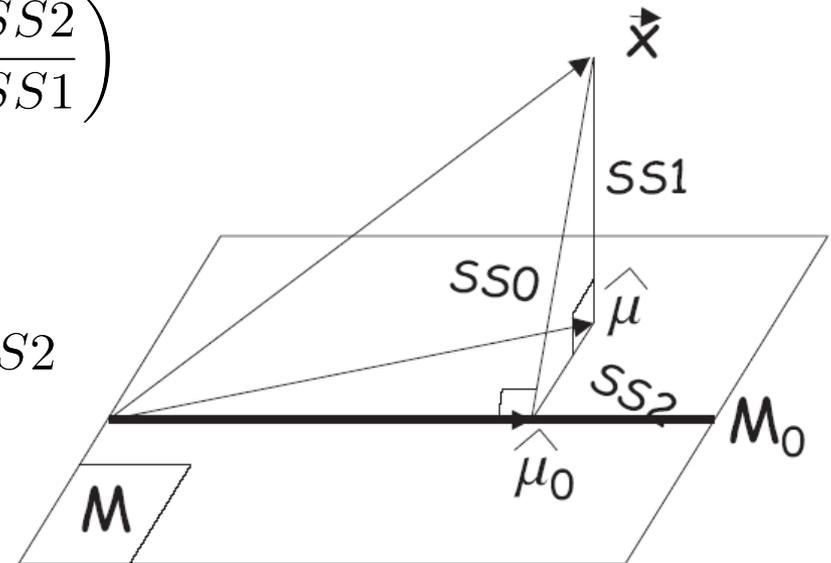
# ANOVA



- La prueba es RELATIVAMENTE más sencilla de lo que parece
  - Con algunas cuenta bastante similares a las que ya hicimos se llega a que el estadístico del test es:

$$T(x) = -\frac{n}{2} \log \left( \frac{SS1}{SS0} \right) = \frac{n}{2} \log \left( 1 + \frac{SS2}{SS1} \right)$$

$$\begin{aligned} & \text{donde } SS0 = \|x - \hat{\mu}_0\|^2 \\ & = \underbrace{\|x - \hat{\mu}\|^2}_{\perp M} + \underbrace{\|\hat{\mu} - \hat{\mu}_0\|^2}_{\in M} = SS1 + SS2 \end{aligned}$$



- Y se puede probar que  $f$  tiene distribución Fisher lo que resulta en el teorema



# ANOVA



- La interpretación intuitiva que me parece la más clara es la siguiente:

$$T(x) = \frac{n}{2} \log \left( \frac{SS0}{SS1} \right)$$

$$\left. \begin{array}{l} SS0 = \|x - \hat{\mu}_0\|^2 \\ SS1 = \|x - \hat{\mu}\|^2 \end{array} \right\} \Rightarrow \frac{SS0}{SS1} = \frac{s_{n(0)}^2}{s_n^2}$$

ANOVA = ANalysis Of  
VAriance

donde  $s_{n(0)}^2 = \frac{1}{n-1} \|x - \hat{\mu}_0\|^2 = \frac{1}{n-1} \|x - \hat{\mu}\|^2 + \frac{n}{n-1} \|\hat{\mu} - \hat{\mu}_0\|^2$

$$s_n^2 = \frac{1}{n-1} \|x - \hat{\mu}\|^2$$

- Sea  $\mu = (\mu_1, \dots, \mu_n)$ 
  - Si  $\mu$  está en  $M_0$  entonces SS0 será similar a SS1 (ambas proyecciones deberían ser similares)
  - Si  $\mu$  no está en  $M_0$  entonces SS0 será grande con respecto a SS1

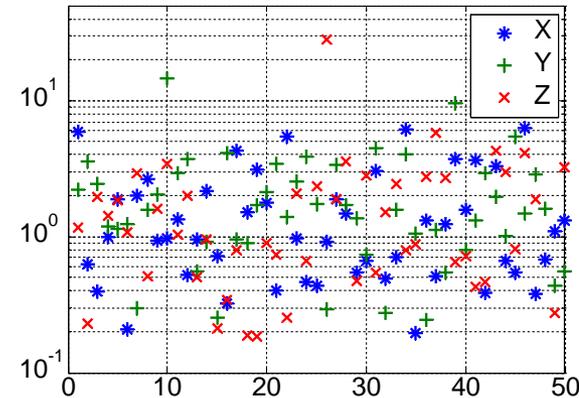
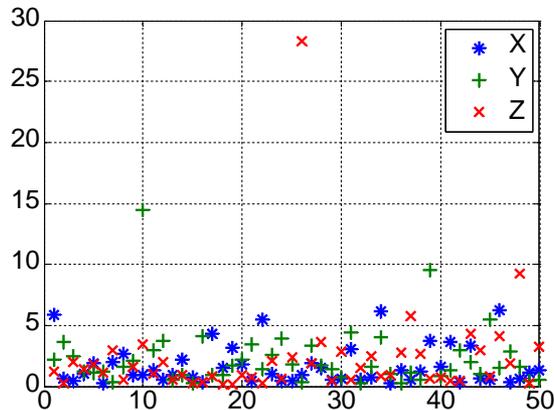




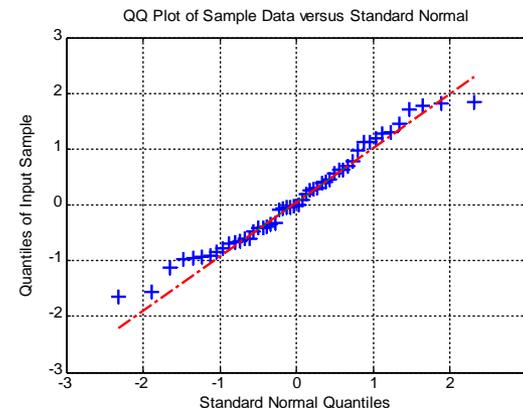
# ANOVA - Ejemplo



- Imaginemos que tenemos tres routers, a los cuales se les hacen una serie de experimentos que miden el throughput promedio (el vector con las medidas para cada equipo los notaremos como  $x$ ,  $y$  y  $z$ )
  - Queremos saber si los tres son equivalentes



- El logaritmo de los datos parece normal
  - Ejemplo con  $x$
- Redefinamos los datos como su logaritmo

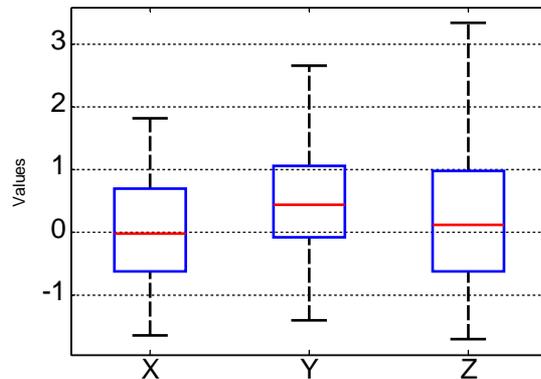




# ANOVA - Ejemplo



- Empecemos con lo más fácil:
  - Boxplot a ver si la diferencia no es evidente



- Y parece tener una media mayor
- Hagamos un intervalo de confianza de la media
  - I de C ( $\mu_x$ ) = [-0.14152 , 0.37081]
  - I de C ( $\mu_y$ ) = [0.14944 , 0.66886]
  - I de C ( $\mu_z$ ) = [-0.11191 , 0.49079]
  - Sigue pareciendo que la media es mayor para y que el resto
    - Pero los I de C se solapan bastante: la diferencia puede ser debida a la aleatoriedad de los datos y no porque las medias sean verdaderamente distintas



# ANOVA - Ejemplo



- Apliquemos ANOVA en este caso:

$$M = (\mu_x, \dots, \mu_x, \mu_y, \dots, \mu_y, \mu_z, \dots, \mu_z) \quad \mu_x, \mu_y, \mu_z \in R$$

$$M_0 = (\mu, \dots, \mu) \quad \mu \in R$$

$$k = \dim M = 3; \quad k_0 = \dim M_0 = 1$$

$$\begin{aligned} \hat{\mu}_0 &= \Pi_{M_0}(x, y, z) = \\ &= \left( \frac{1}{n_x + n_y + n_z} \left( \sum_{i=1}^{n_x} x_i + \sum_{i=1}^{n_y} y_i + \sum_{i=1}^{n_z} z_i \right) \right) * \text{ones}(1, n_x + n_y + n_z) \end{aligned}$$

$$\begin{aligned} \hat{\mu} &= \Pi_M(x, y, z) = \\ &= \left[ \frac{1}{n_x} \left( \sum_{i=1}^{n_x} x_i \right) * \text{ones}(1, n_x), \frac{1}{n_y} \left( \sum_{i=1}^{n_y} y_i \right) * \text{ones}(1, n_y), \frac{1}{n_z} \left( \sum_{i=1}^{n_z} z_i \right) * \text{ones}(1, n_z) \right] \end{aligned}$$

$$SS2 = \|\hat{\mu} - \hat{\mu}_0\|^2; \quad SS1 = \|x - \hat{\mu}\|^2$$

$$f = \frac{SS2/(k - k_0)}{SS1/(n - k)} \approx 3.25$$

$$p^* = F_{2, n_x + n_y + n_z - 3}(f) \approx 0.669$$





# ANOVA - Ejemplo



- $p^*=0.669 \Rightarrow$  no puedo rechazar  $H_0$
- Es decir, la diferencia en las medias no es tan grande como para no poder atribuírsela a la aleatoriedad de los datos
- ¿Qué falta testear?
  - Independencia
  - Idénticamente distribuidos en cada grupo
  - Que fueran todos normales
  - Que la varianza fuera igual para todos
    - Es decir, las hipótesis del test
    - Es muy importante “testear el test” pues si no estamos en sus hipótesis el resultado pierde significado



# Agenda



- Neyman-Pearson
- Likelihood Ratio Tests
- ANOVA
- Resultados asintóticos
- Otros tests...

# Resultados Asintóticos

- Sea un likelihood ratio test; i.e.

$$\begin{cases} H_0 : \theta \in \Theta_0 \\ H_1 : \theta \in \Theta \setminus \Theta_0 \end{cases} \quad C(x) = \{x : T(x) = l_x(H_1) - l_x(H_0) > k\}$$

- Más en particular (además de algunas condiciones de regularidad básicas):

$$\Theta = \Theta_1 \times \Theta_2$$

con  $\Theta_1$  subconjunto abierto de  $R^{q_1}$

y  $\Theta_2$  subconjunto abierto de  $R^{q_2}$

Sea  $\theta = (\theta_1, \theta_2)$   $\theta_1 \in \Theta_1, \theta_2 \in \Theta_2$

$$\begin{cases} H_0 : \theta_2 = 0 \\ H_1 : \theta_2 \neq 0 \end{cases}$$

- Para muestras grandes, y bajo  $H_0$ , es válida la siguiente aproximación:  $2T(X) \sim \chi_{q_2}^2$

- Por lo tanto tenemos la siguiente aproximación:

$$p^* \approx 1 - F_{\chi_{q_2}^2}(2T(x))$$



# Aplicación 1: Test de Ajuste



- Tenemos  $x_1, \dots, x_n$  que asumimos generados por  $n$  V.A. iid  $X_1, \dots, X_n$
- Queremos verificar si la distribución  $F()$  de  $X_i$  viene de una cierta familia de distribuciones paramétrica en  $\theta$  (con  $\theta$  en cierto espacio  $\Theta_0$ )
- Idea :
  - Hagamos un histograma de  $k$  bins de los datos
  - Si la distribución es  $F(x, \theta) \Rightarrow$  la probabilidad de que  $X_i$  esté en el bin  $j$  es  $q_j(\theta) = F(M_j, \theta) - F(m_j, \theta)$  (el caso multidimensional es análogo)
  - Si  $N_j$  es una V.A. que indica la cantidad de datos que cayeron en el bin  $j \Rightarrow N = (N_1, \dots, N_k)$  sigue una distribución multinomial de parámetros  $n$  y  $q(\theta) = (q_1(\theta), \dots, q_k(\theta))$



# Aplicación 1: Test de Ajuste



- Por lo tanto el test resultante es:

$$\begin{cases} H_0 : N \sim M_{n,q(\theta)} \text{ con } \theta \in \Theta_0 \\ H_1 : N \sim M_{n,p} \text{ con } p \text{ cualquiera} \end{cases}$$

- Desarrollemos un likelihood ratio test para este caso:

$$P(N_1 = n_1, \dots, N_k = n_k) = \frac{n!}{n_1! \dots n_k!} q_1(\theta)^{n_1} \dots q_k(\theta)^{n_k}$$

$$\Rightarrow l_x(H_0) = \sup_{\theta \in \Theta_0} K + \sum_{i=1}^k n_i \log(q_i(\theta)) = K + \sum_{i=1}^k n_i \log(q_i(\theta^*))$$

(donde asumimos que sabemos calcular  $\theta^*$ )

- Es relativamente fácil probar que

$$l_x(H_1) = C + \sum_{i=1}^k n_i \log\left(\frac{n_i}{n}\right)$$





# Aplicación 1: Test de Ajuste



- Por lo tanto el test resultante es:

$$\begin{cases} H_0 : N \sim M_{n,q(\theta)} \text{ con } \theta \in \Theta_0 \\ H_1 : N \sim M_{n,p} \text{ con } p \text{ cualquiera} \end{cases}$$

- Desarrollemos un likelihood ratio test para este caso:

$$\Rightarrow l_x(H_1) - l_x(H_0) = T(x) = \sum_{i=1}^n n_i \log \left( \frac{n_i}{nq_i(\theta^*)} \right)$$

$$\Rightarrow p^* = \sup_{\theta \in \Theta_0} P \left( \sum_{i=1}^k N_i \log \left( \frac{N_i}{nq_i(\theta^*)} \right) > \sum_{i=1}^k n_i \log \left( \frac{n_i}{nq_i(\theta^*)} \right) \right)$$

- Para  $\theta$  fijo ya es difícil de calcular ¿cómo encuentro el supremo?
- Utilicemos el resultado asintótico:  $q_2 = k - \dim(\Theta_0) - 1$  (¿cuántas dimensiones agrega  $H_1$  con respecto a  $H_0$ ?)

$$p^* \approx 1 - F_{\chi_{k - \dim \Theta_0 - 1}^2} \left( 2 \sum_{i=1}^n n_i \log \left( \frac{n_i}{nq_i(\theta^*)} \right) \right)$$





# Test de Ajuste - Ejemplo



- Hagamos un ejemplo con los datos que teníamos de los routers, para verificar que  $\log(x)$ ,  $\log(y)$  y  $\log(z)$  son normales
- Ejemplo con  $\log(x)$ 
  - $\theta = (\mu, \sigma^2)$
  - $\theta^* = (\mu^*; \sigma^{*2}) = (\sum x_i / n_x; \sum (x_i - \mu^*)^2 / n_x)$
  - Elegí  $k=10$
  - $q(\theta^*) = [0.015 \quad 0.040 \quad 0.086 \quad 0.14 \quad 0.19 \quad 0.19 \quad 0.16 \quad 0.097 \quad 0.048 \quad 0.018]$
  - $N/n = [0.02 \quad 0.06 \quad 0.09 \quad 0.1 \quad 0.19 \quad 0.18 \quad 0.21 \quad 0.1 \quad 0.04 \quad 0.01]$
  - $T(x) = 3.72$
  - $p^* = 0.38$
- $\Rightarrow$  No puedo rechazar la hipótesis que  $\log(X)$  es normal



# Aplicación 2: Test de Independencia.



- Tenemos  $(x_1, y_1), \dots, (x_n, y_n)$  que asumimos generados por  $n$  vectores aleatorios iid  $Z_1, \dots, Z_n$  con  $Z_i = (X_i, Y_i)$
- Queremos saber si  $X_i$  y  $Y_i$  son independientes entre sí
- La idea es similar a la anterior:

- Partimos los datos de  $X$  [ $Y$ ] en  $I$  [ $J$ ] bins  $B_i$  [ $C_j$ ]
- Sea  $N_{ij}$  una V.A. que indica cuántos datos cayeron en el contenedor  $B_i$  y  $C_j$  y  $N$  un vector conteniendo los  $N_{ij}$ :

$$N_{ij} = \sum_{i=1}^n 1_{\{B_i\}}(X_i) 1_{\{C_j\}}(Y_i)$$

- Sea  $p_{ij}$  la probabilidad de que  $Z_i$  esté en  $B_i$  y  $C_j$  y  $p$  un vector conteniendo los  $p_{ij}$ :

$$p_{ij} = P(X_i \in B_i \text{ y } Y_i \in C_j)$$

- Como en el caso anterior  $N$  es multinomial de parámetros  $n$  y  $p$



# Aplicación 2: Test de Independencia.



- El test resulta entonces:

$$\begin{cases} H_0 : N_{ij} \sim M_{n,p} \text{ con } p_{ij} = q_i r_j : \sum_i q_i = 1 \text{ y } \sum_j r_j = 1 \\ H_1 : N_{ij} \sim M_{n,p} \text{ con } p_{ij} \text{ cualquiera} \end{cases}$$

- Desarrollemos un likelihood ratio test para este caso:
  - Queda como ejercicio probar que

$$l_x(H_0) = C + \sum_{i,j} \log \left( \frac{n_i n_j}{n} \right) \quad \left( \text{donde } n_i = \sum_j n_{ij} \text{ y } n_j = \sum_i n_{ij} \right)$$
$$l_x(H_1) = C + \sum_{i,j} \log \left( \frac{n_{ij}}{n} \right)$$
$$\Rightarrow T(n) = \sum_{i,j} n_{ij} \log \left( \frac{n n_{ij}}{n_i n_j} \right)$$



# Aplicación 2: Test de Independencia.



- El test resulta entonces:

$$\begin{cases} H_0 : N_{ij} \sim M_{n,p} \text{ con } p_{ij} = q_i r_j : \sum_i q_i = 1 \text{ y } \sum_j r_j = 1 \\ H_1 : N_{ij} \sim M_{n,p} \text{ con } p_{ij} \text{ cualquiera} \end{cases}$$

- Desarrollemos un likelihood ratio test para este caso:

- Nuevamente nos vemos obligados a utilizar la aproximación asintótica
- ¿Cuánto vale  $q_2$ ?
  - ¿Cuántas dimensiones le agrega  $H_1$  a  $H_0$ ?
  - $\dim(\theta) = \dim(p)$
  - Bajo  $H_1$   $p$  lo único que debe cumplir es que sume 1  $\Rightarrow \dim(p, H_1) = IJ - 1$
  - Bajo  $H_0$   $p$  es el producto de dos valores que suman 1  $\Rightarrow \dim(p, H_0) = (I-1) + (J-1)$
  - $q_2 = \dim(p, H_1) - \dim(p, H_0) = (I-1)(J-1)$

$$\Rightarrow p^* \approx 1 - F_{\chi^2_{(I-1)(J-1)}} \left( 2 \sum_{i,j} n_{ij} \log \left( \frac{n n_{ij}}{n_i n_j} \right) \right)$$



# Test de Independencia: Ejemplo

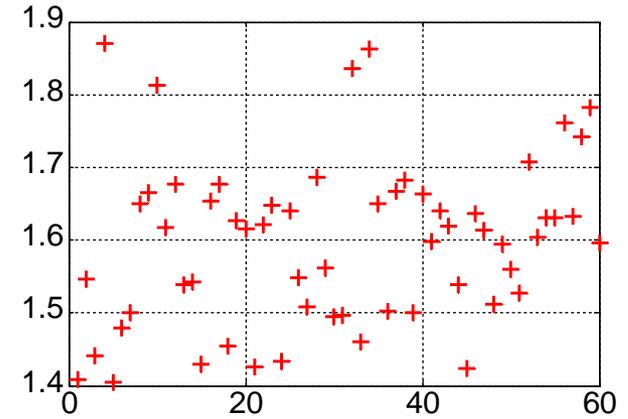
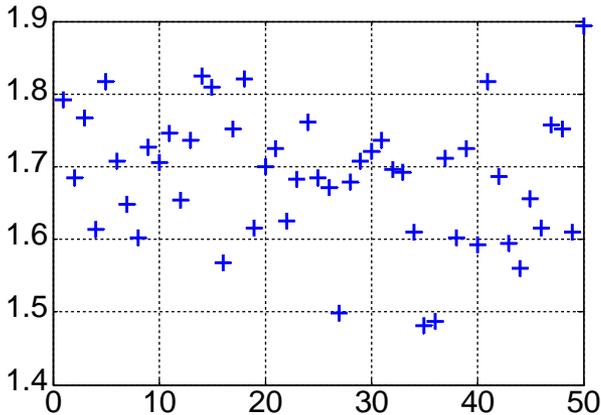


- Tenemos  $n$  datos de altura de personas, de las cuales también conocemos el sexo
- Asumamos que los datos fueron generados por  $n$  vectores aleatorios iid  $Z_1, \dots, Z_n$  con  $Z_i = (X_i, Y_i)$ 
  - $X_i$  vale 1 si la persona es hombre
  - $X_i$  vale 0 si la persona es mujer
  - $Y_i$  indica la altura
- Si la encuesta estuvo bien hecha los datos deberían ser iid
- La pregunta que nos hacemos es:
  - ¿Son la altura y el sexo independientes?



# Test de Independencia: Ejemplo

## ■ Datos:



## ■ Uso cinco bins para las alturas y dos para el sexo:

- $n_{ij} = \begin{matrix} 3 & 4 & 19 & 18 & 6 \\ 15 & 13 & 24 & 4 & 4 \end{matrix}$
- $n_i = 50 \quad 60$
- $n_j = 18 \quad 17 \quad 43 \quad 22 \quad 10$
- $T(n) = 11.7$
- $p^* = 0.1 \times 10^{-3}$

=> Tengo que rechazar  $H_0$ , son claramente dependientes!



# Agenda



- Neyman-Pearson
- Likelihood Ratio Tests
- ANOVA
- Resultados asintóticos
- Otros tests...



# Otros tests

- Obviamente no vimos ni cerca todos los tests posibles
- Por ejemplo, dejamos afuera toda una familia de tests
  - Los tests no paramétricos
    - no se testea sobre un parámetro de una distribución
- Ejemplos son los tests de iid-ismo

$$\begin{cases} H_0 : X_1, \dots, X_n \text{ son iid} \\ H_1 : X_1, \dots, X_n \text{ no son iid} \end{cases}$$

- Vemos un test como este a continuación





# Test de Turning Point



- Tenemos  $x_1, \dots, x_n$  que asumimos generados por  $n$  V.A.  $X_1, \dots, X_n$
- Se dice que la serie  $x_1, \dots, x_n$  es monótona en  $i$  si  $x_{i-1} \leq x_i \leq x_{i+1}$  o  $x_{i-1} \geq x_i \geq x_{i+1}$
- Se dice que la serie tiene un “turning point” en  $i$  si la serie no es monótona en  $i$
- Sea  $T$  la cantidad de “turning points”
- El p-valor del test de turning point es para  $n$  grande:

$$p^* = 2 \left( 1 - F_{N_{0,1}} \left( \frac{|T - \frac{2n-4}{3}|}{\sqrt{\frac{16n-29}{90}}} \right) \right)$$



# Bibliografía



- Para los temas “Simulación”, “Presentando los Datos” y “Tests” basé las presentaciones en el libro “Performance Evaluation of Computer and Communication Systems” de Jean-Yves Le Boudec (ed. EPFL Press)
- Para el obligatorio quizás quieran y/o necesiten otros tests o intervalos de confianza
  - El libro “Probabilidad y Estadística Matemática: Un Primer Encuentro” de Gonzalo Perera (editado por la Oficina de Publicaciones del CEI) tiene muchos tests e I. de C.
  - Internet también es una buena fuente (recuerden que Timbó da acceso a los libros editados por Elsevier)
- **ATENCIÓN:** Siempre verifiquen las hipótesis de los métodos con los que trabajen!

