



# Presentando los Datos

**Modelado y Análisis de Redes  
de Telecomunicaciones**




UNIVERSIDAD  
DE LA REPUBLICA  
URUGUAY



# Presentando los Datos



- Estoy haciendo el benchmarking de un procesador
  - Ejecuto cien veces la misma serie de operaciones y mido el tiempo que demora en ejecutarlas
  - ¿qué le muestro a mi jefe?
    - ¿todas?






# Presentando los Datos



- Estoy haciendo el benchmarking de un procesador
  - Ejecuto cien veces la misma serie de operaciones y mido el tiempo que demora en ejecutarlas
  - ¿qué le muestro a mi jefe?
    - ¿el promedio?






# Presentando los Datos




- Estoy haciendo el benchmarking de un procesador
  - Ejecuto cien veces la misma serie de operaciones y mido el tiempo que demora en ejecutarlas
  - ¿qué le muestro a mi jefe?
    - ¿asumo que los datos son normales y le muestro la media más/menos dos veces la varianza?



# Presentando los Datos




- Estoy haciendo el benchmarking de un procesador
  - Ejecuto cien veces la misma serie de operaciones y mido el tiempo que demora en ejecutarlas
  - ¿qué le muestro a mi jefe?
    - ¿muestro la mediana y un par de cuantiles?



# Presentando los Datos

- Estoy haciendo el benchmarking de un procesador
  - Ejecuto cien veces la misma serie de operaciones y mido el tiempo que demora en ejecutarlas
  - ¿qué le muestro a mi jefe?
    - ¿muestro un histograma?






# Presentando los Datos



- Estoy haciendo el benchmarking de un procesador
  - Ejecuto cien veces la misma serie de operaciones y mido el tiempo que demora en ejecutarlas
  - ¿qué le muestro a mi jefe?
    - ¿muestro un distribución empírica?





# Presentando los Datos



- Estoy haciendo el benchmarking de un procesador
  - Ejecuto cien veces la misma serie de operaciones y mido el tiempo que demora en ejecutarlas
  - ¿qué le muestro a mi jefe?
    - ¿Qué garantías tengo acerca de la correctitud o sentido de lo que mostré?
    - I.e. ¿El jefe me pregunta “¿y porqué 100 valores?” y qué le digo?







# Agenda



- **Histogramas y distribuciones empíricas**
- (Media, Varianza) y (Mediana, Cuantiles)
- Intervalos de Confianza
- Intervalos de Predicción
- Comentario Finales







# Histograma

- Sean  $x_1, \dots, x_n$   $n$  realizaciones de un experimento
- Sean  $m = \min\{x_1, \dots, x_n\}$  y  $M = \max\{x_1, \dots, x_n\}$ 
  - Tomo  $k$  sub-intervalos (*bins*)  $B_i$  ( $i=1, \dots, k$ ) de ancho  $w = (M-m)/k$  como  $B_i = (m + (i-1)w ; m + iw]$
  - La función histograma  $h(x)$  se define para  $x \in B_i$  como:

$$h(x) = \sum_{i=1}^n 1_{\{x_i \in B_i\}}$$

i.e. la cantidad de datos que cayeron en el  $i$ -ésimo bin



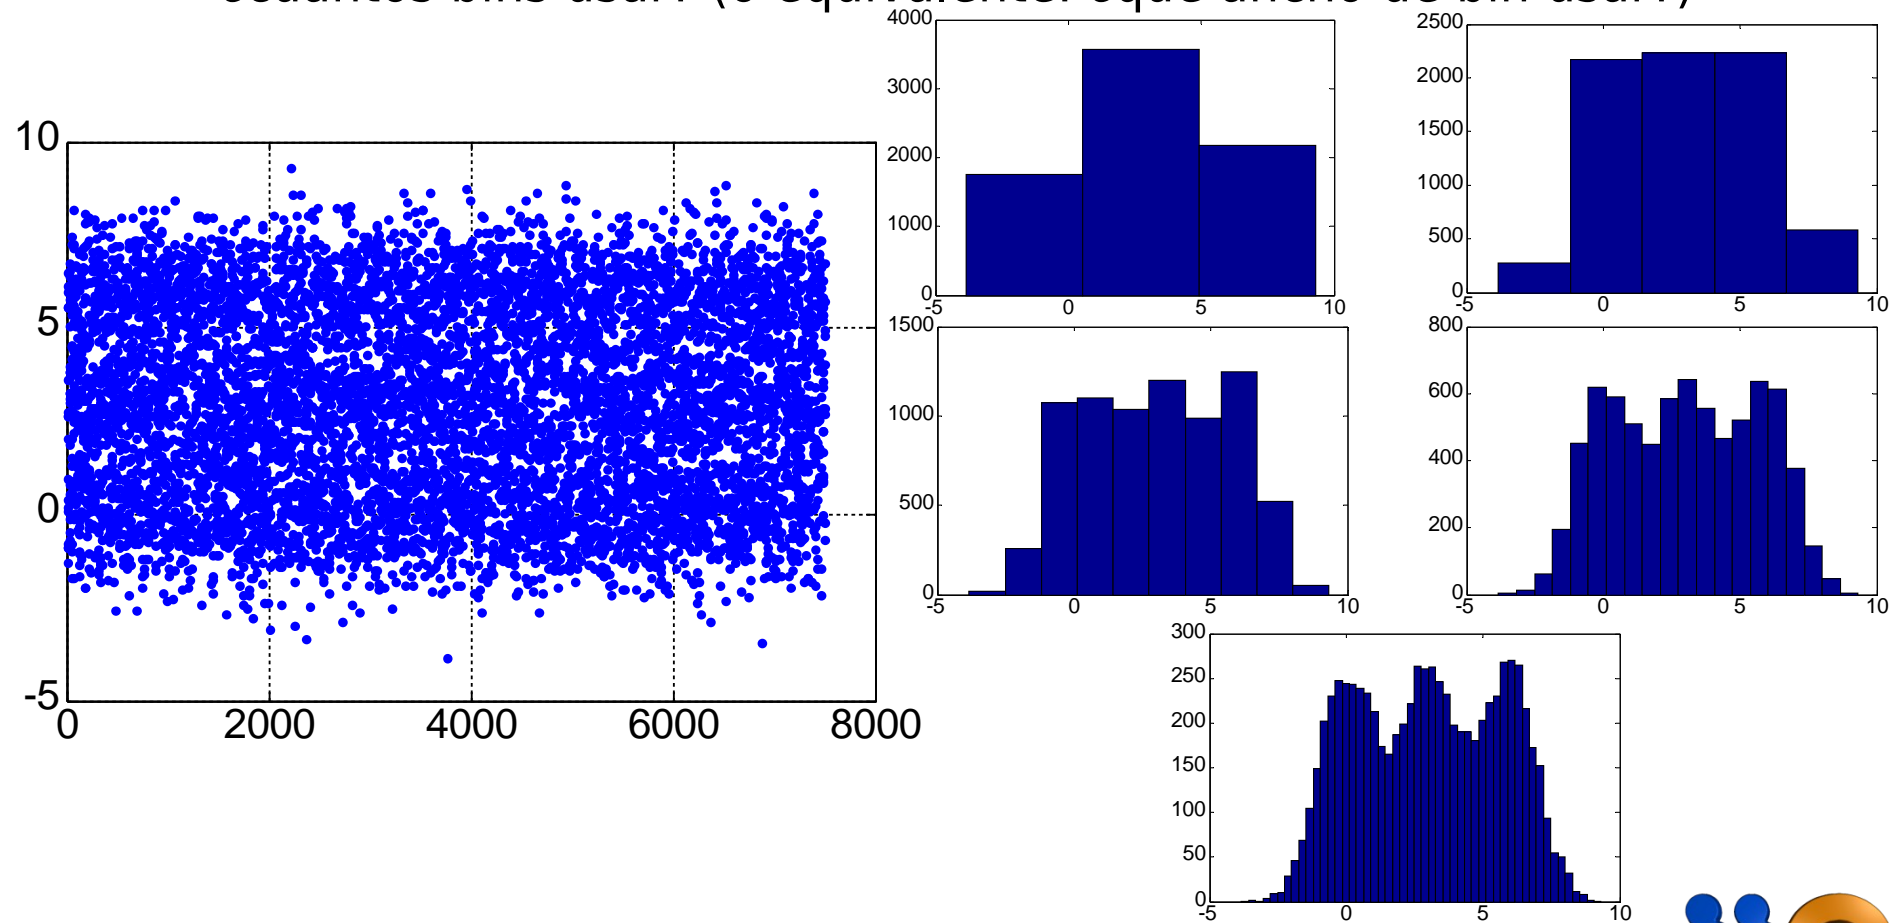


# Histograma



## ■ Dos problemas:

- No es suave
- ¿cuántos bins usar? (o equivalente: ¿qué ancho de bin usar?)





# Histograma



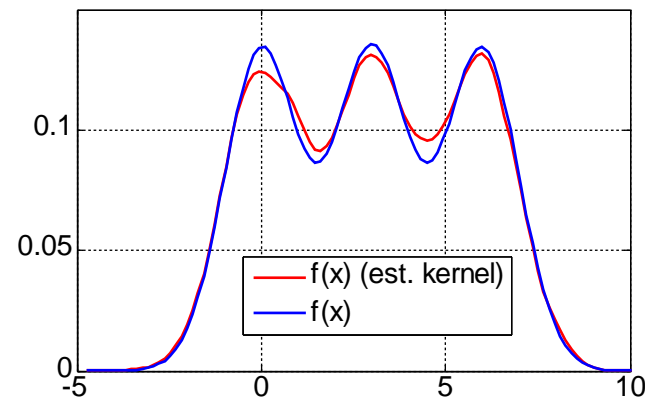
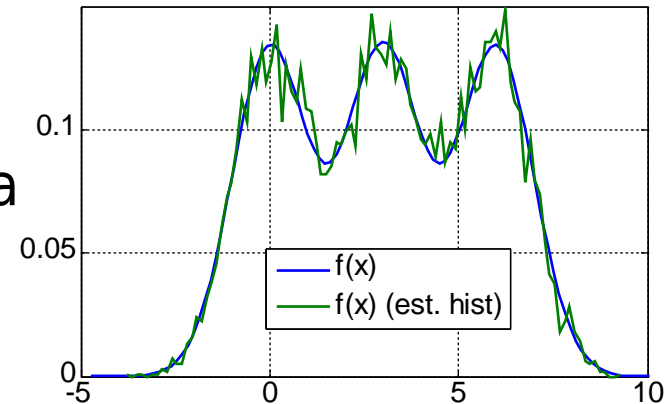

## ■ ¿Qué es el histograma?

- Sean  $X_1, \dots, X_n$  V.A. iid con densidad  $f(x)$  y  $x_1, \dots, x_n$  una realización
- Si  $x$  está en  $B_i$  entonces  $h(x)/n \rightarrow P(X_i \in B_i) \approx f(x)w$
- Por lo tanto  $h(x)$  no es más que una aproximación tosca de la densidad (a excepción del re-escalado)

## ■ Existen otras técnicas más sofisticadas para estimar la densidad de $X_i$

- Ejemplo: estimación por kernels (donde  $K(x)$  puede ser por ejemplo la campana de Gauss o un rectángulo de ancho  $h$ )

$$\hat{f}(x) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x - x_i}{h}\right)$$







# Distribución Empírica



- La distribución empírica  $F_n(x)$  de los valores  $x_1, \dots, x_n$  se define como:

$$F_n(x) = \frac{1}{n} \sum_{i=1}^n 1_{\{x_i \leq x\}}$$



- Sean  $X_1, \dots, X_n$  V.A. iid con distribución  $F(x)$  y  $x_1, \dots, x_n$  una realización
  - Entonces  $F_n(x)$  es una estimación de la función de distribución de  $X_i$





# Distribución Empírica



- Sean  $X_1, \dots, X_n$  V.A. iid con distribución  $F(x)$  y  $x_1, \dots, x_n$  una realización
  - Entonces  $F_n(x)$  es una estimación de la función de distribución de  $X_i$
- Esto se justifica por el teorema de Glivenko-Cantelli

$$\sup_{t \in \mathbb{R}} |F_n(t) - F(t)| \xrightarrow[n]{} 0 \quad \text{c.s.}$$

- Prueba parcial (¿Porqué no es completa?):

$$Y_i = 1_{\{X_i \leq t\}} \Rightarrow E\{Y_i\} = P(X_i \leq t) = F(t)$$
$$\stackrel{\text{LFGN } (Y_i \text{ iid})}{\Rightarrow} F_n(t) = \frac{1}{n} \sum_{i=1}^n Y_i \xrightarrow[n]{} E\{Y_1\} = F(t) \quad \text{c.s.}$$

- Por lo general es preferible utilizar la ECDF que una estimación de densidades pues la primera no tiene parámetros






# Comparación de Distribuciones



- Hasta ahora veníamos comparando distribuciones graficando sus distribuciones
  - ¿qué tiene de malo?
  - E.g.  $X=(X_1+X_2)/2$  con  $X_i \sim U[-2.45, 2.45]$  e  $Y \sim N_{0,1}$






# Comparación de Distribuciones



- Para una comparación visual de las distribuciones es mejor el **QQ plot**
- La idea es graficar para ciertos valores de  $q$  el valor del cuantil de orden  $q$  de las dos distribuciones  $(\alpha_q^X, \alpha_q^Y)$
- Si las distribuciones son iguales (salvo un re-escalado y/o una traslación) entonces los puntos debería seguir una recta








# Comparación de Distribuciones



- En realidad, su uso más corriente es para:
  - Comparar dos muestras a ver si provienen de la misma distribución
    - Sean  $x_{(1)}, \dots, x_{(n)}$  los valores de  $x_1, \dots, x_n$  ordenados de menor a mayor
    - Para comparar dos muestras se grafica  $(x_{(i)}, y_{(i)})$  para  $i=1, \dots, n$
    - La idea es que  $x_{(i)}, y_{(i)}$  son buenas estimaciones del mismo cuantil
    - Ejemplo: dos muestras normales (atención que en este caso hay que ser más “tolerante” con las desviaciones de la recta)






# Comparación de Distribuciones



- En realidad, su uso más corriente es para:
  - Comparar una muestra para ver si proviene de una distribución dada
  - En este caso se grafica  $(x_{(i)}, E\{X_{(i)}\})$
  - ¿ $E\{X_{(i)}\}$ ? Una buena aproximación si  $F$  (la distribución de  $X$ ) es creciente es  $F^{-1}(i/(n+1))$
  - Ejemplo: una muestra normal





# Agenda



- Histogramas y distribuciones empíricas
- (Media, Varianza) y (Mediana, Cuantiles)
- Intervalos de Confianza
- Intervalos de Predicción
- Comentario Finales





# Media



- En vez de mostrar todos los datos o de mostrar toda la distribución, muchas veces es necesario algo más concreto
  - Un valor representativo y su variabilidad alrededor de él
  - Dos candidatos
    - Media y varianza
    - Mediana y cuantiles





# Media y Varianza



■ Sean  $X_1, \dots, X_n$  V.A.

- La media empírica se define:

$$\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$$

- La varianza empírica se define (ver en el práctico el porqué de estas dos definiciones y porqué  $s_n^2$  es mejor):

$$\sigma_n^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2 \quad \text{o} \quad s_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$$

■ **IMPORTANTE:** notar que estos indicadores son V.A. y por lo tanto son aleatorios



# Media y Varianza



- Ejemplo: la media empírica
  - En el caso que  $X_1, \dots, X_n$  tengan esperanza y sean para todas la misma:

$$E\{\bar{X}_n\} = E\left\{\frac{1}{n} \sum_{i=1}^n X_i\right\} = \frac{1}{n} \sum_{i=1}^n E\{X_i\} = E\{X_1\}$$

- Además, si  $n$  es suficientemente grande,  $X_1, \dots, X_n$  son iid y tienen varianza  $\sigma^2$  finita:

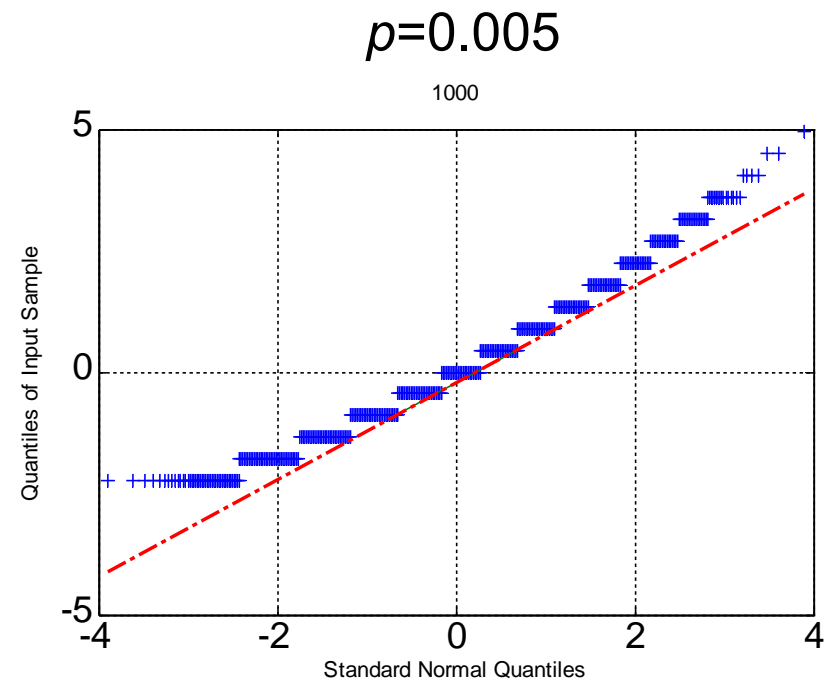

$$\frac{\bar{X}_n - E\{X_1\}}{\sigma/\sqrt{n}} \sim N_{0,1} \Rightarrow \bar{X}_n \sim N_{E\{X_1\}, \sigma^2/n}$$



# Media y Varianza



- Al respecto del  $n$  grande y la aplicación del TCL
  - $X_i \sim \text{Ber}(p)$  ( $P(X_i=1)=p$ ;  $P(X_i=0)=1-p$ )
  - 1000 muestras para hacer el promedio ( $n=1000$ )





# Mediana y Cuantiles



- Sean  $X_1, \dots, X_n$  V.A. y  $X_{(1)}, \dots, X_{(n)}$  las mismas V.A. ordenadas de menor a mayor
- El cuantil empírico de orden  $q$  se define como

$$\alpha_{n,q} = \frac{X_{(k')} + X_{(k'')}}{2}$$

donde  $k' = \lfloor qn + (1 - q) \rfloor$  y  $k'' = \lceil qn + (1 - q) \rceil$

- Ejemplo: la mediana empírica
  - Si  $n$  es par  $\Rightarrow \alpha_{n,0.5} = (X_{n/2} + X_{(n+1)/2})/2$
  - Si  $n$  es impar  $\Rightarrow \alpha_{n,0.5} = X_{(n+1)/2}$







# Ejemplos gráficos





- El mismo benchmarking sobre dos procesadores






# Histogramas



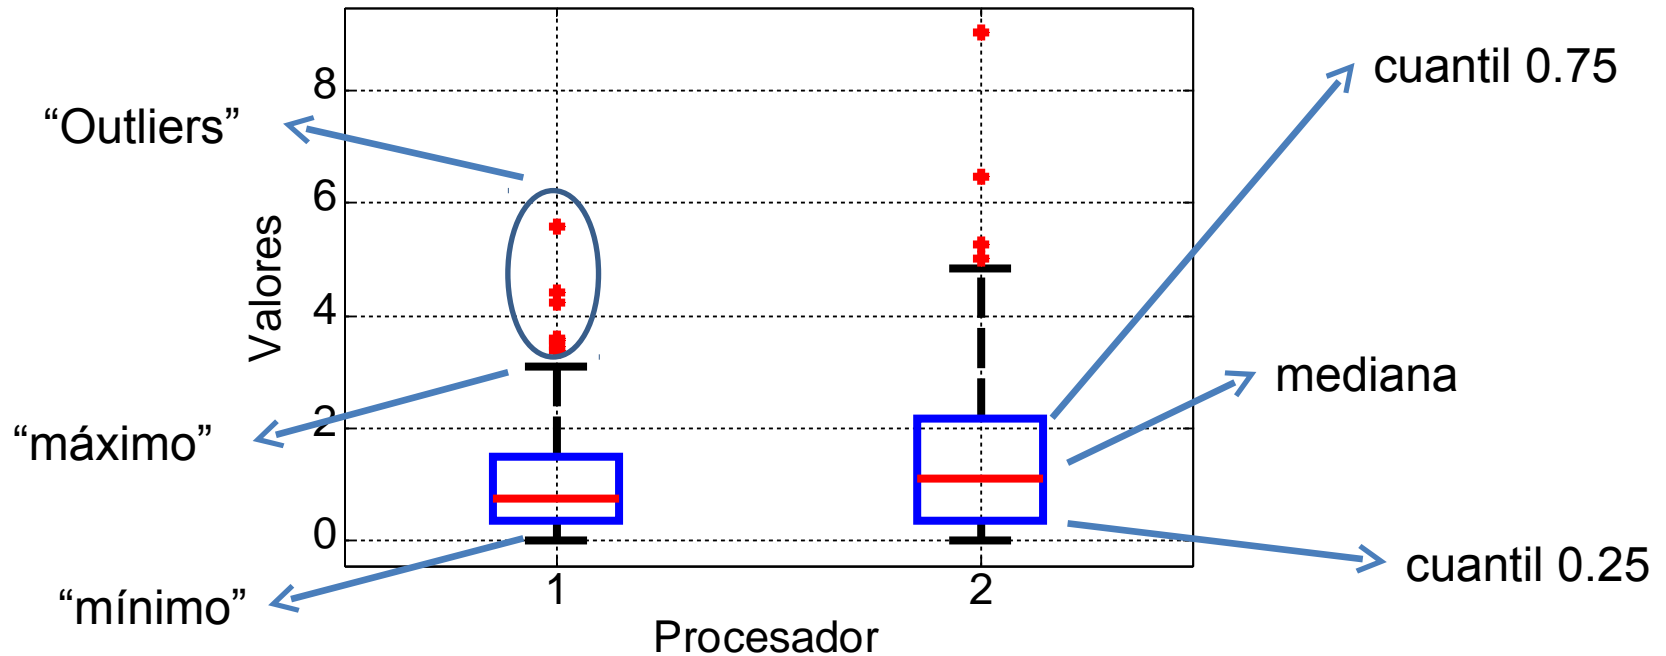


# ECDFs





# Boxplots





# Agenda



- Histogramas y distribuciones empíricas
- (Media, Varianza) y (Mediana, Cuantiles)
- Intervalos de Confianza
- Intervalos de Predicción
- Comentario Finales





# Intervalos de Confianza



- Imaginemos que tenemos un montón de datos y nos decidimos a mostrar a modo de resumen la media
- Asumamos que estos  $n$  números fueron generados por  $n$  V.A. iid  $X_1, \dots, X_n$ 
  - En realidad idealmente quisiéramos mostrar  $E\{X_1\}$
  - Sabemos que la mejor aproximación es el promedio  $\Sigma X_i/n$
  - Pero también sabemos que el promedio es otra V.A.
  - Dos preguntas:
    - ¿Qué tan cerca está el promedio de la esperanza?
    - ¿A partir de  $X_1, \dots, X_n$  podemos calcular un intervalo en el cual la esperanza se encuentre con alta probabilidad?
      - ATENCIÓN: A partir de  $X_1, \dots, X_n$  solamente (nada sabemos por ejemplo de  $F()$ )





# Intervalos de Confianza



## ■ Más en general

- Sea  $m$  un parámetro de la distribución  $F()$  cualquiera (la esperanza, la varianza, etc.)
  - $F()$  se asume fijo pero desconocido (por lo tanto también  $m$ )
- Sean  $X_1, \dots, X_n$   $n$  V.A. iid con distribución  $F()$
- Un intervalo de confianza de nivel  $\gamma$  para el parámetro  $m$  es un intervalo de la forma  $(u(X_1, \dots, X_n), v(X_1, \dots, X_n))$  tal que:

$$P(u(X_1, \dots, X_n) < m < v(X_1, \dots, X_n)) \geq \gamma$$

## ■ REPITO: $m$ es fijo, lo aleatorio es el intervalo

- Imaginen que sé calcular un intervalo de confianza a nivel 0.95 para la esperanza
- Genero 1000 realizaciones de las  $n$  V.A.  $X_1, \dots, X_n$  (con  $X_1 \sim U[0,1]$ ) y a cada una le calculo el intervalo
- ¿Cuántos de esos intervalos contendrán a 0.5?



# Intervalos de Confianza

## ■ Un primer caso “sencillo”: Intervalo de confianza para la esperanza

- Sean  $X_1, \dots, X_n$   $n$  V.A. iid con distribución  $F()$  tal que existen la esperanza y la desviación estándar  $\sigma$
- Sabemos que si  $n$  es suficientemente grande (ver práctico):

$$\left. \begin{aligned} s_n^2 &= \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2 \xrightarrow[n]{\text{c.s.}} \sigma^2 \\ \frac{\bar{X}_n - E\{X_1\}}{\sigma/\sqrt{n}} &\sim N_{0,1} \end{aligned} \right\} \longrightarrow \frac{\bar{X}_n - E\{X_1\}}{s_n/\sqrt{n}} \sim N_{0,1}$$

## ■ Entonces UN POSIBLE intervalo de confianza de nivel $\gamma$ para la media es:

$$\left( \bar{X}_n - z_{\frac{\gamma+1}{2}} \frac{s_n}{\sqrt{n}}, \bar{X}_n + z_{\frac{\gamma+1}{2}} \frac{s_n}{\sqrt{n}} \right) \quad \text{con} \quad F_{N_{0,1}} \left( z_{\frac{\gamma+1}{2}} \right) = \frac{\gamma+1}{2}$$



# Intervalos de Confianza

## ■ Un segundo caso no tan “sencillo”: Intervalo de confianza para la varianza

- Sean  $X_1, \dots, X_n$   $n$  V.A. iid con distribución  $N_{0,1}$
- Se puede probar que:

$$\frac{\bar{X}_n - E\{X_1\}}{s_n/\sqrt{n}} \sim t_{n-1} \quad (n-1) \frac{s_n^2}{\sigma^2} \sim \chi_{n-1}^2$$

- $\chi_n^2$  se llama distribución chi-cuadrado con  $n$  grados de libertad
  - Es la distribución de la V.A. definida como la suma de  $n$  V.A. iid normales elevadas al cuadrado
- $t_n$  se llama distribución de t-student
  - Es la distribución de la V.A. definida como  $X/\sqrt{Y/n}$  con  $X$  normal,  $Y$  chi-cuadrado con  $n$  grados de libertad y ambas independientes

## ■ Entonces UN POSIBLE I. de C. de nivel $\gamma$ para la varianza es:

$$\left( s_n \sqrt{\frac{n-1}{\xi}}, s_n \sqrt{\frac{n-1}{\zeta}} \right) \quad \text{con } F_{\chi_{n-1}^2}(\xi) = \frac{1+\gamma}{2} \text{ y } F_{\chi_{n-1}^2}(\zeta) = \frac{1-\gamma}{2}$$

# Intervalos de Confianza



- ¿Cómo saber si la distribución  $F()$  tiene esperanza y/o varianza si no la conozco a priori?
- Siempre que sea posible, es mejor utilizar cuantiles
  - ¿Cómo calcular intervalos de confianza para los cuantiles?
- Sean  $X_1, \dots, X_n$   $n$  V.A. iid con distribución  $F()$  tal que  $F()$  tiene densidad y  $X_{(1)}, \dots, X_{(n)}$  los estadísticos de orden
  - Sea  $\alpha_q$  el cuantil de orden  $q \Rightarrow F(\alpha_q) = q$
  - Un intervalo de confianza de nivel  $\gamma$  para  $\alpha_q$  es:

$$(X_{(j)}, X_{(k)})$$

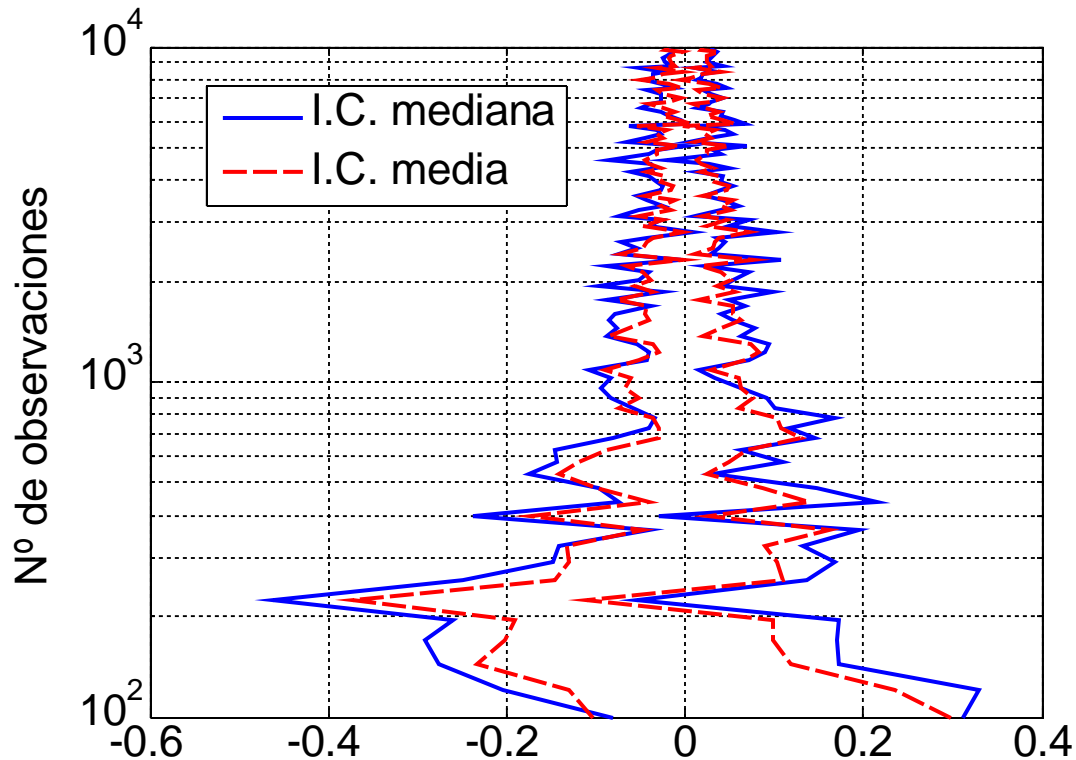
Donde  $j$  y  $k$  satisfacen

$$F_{\text{Bin}_{n,q}}(k-1) - F_{\text{Bin}_{n,q}}(j-1) \geq \gamma$$

- $X \sim \text{Bin}_{n,q}$  se denomina binomial de parámetros  $n$  y  $q$ , definida como  $X = \sum Y_i$  ( $i=1, \dots, n$ ) con  $P(Y_i=1)=q$  y  $P(Y_i=0)=1-q$  ( $Y_i$  independientes)
- Ejemplo: I. de C. de nivel 0.95 para la mediana con  $n=10$  es  $(X_{(2)}, X_{(9)})$

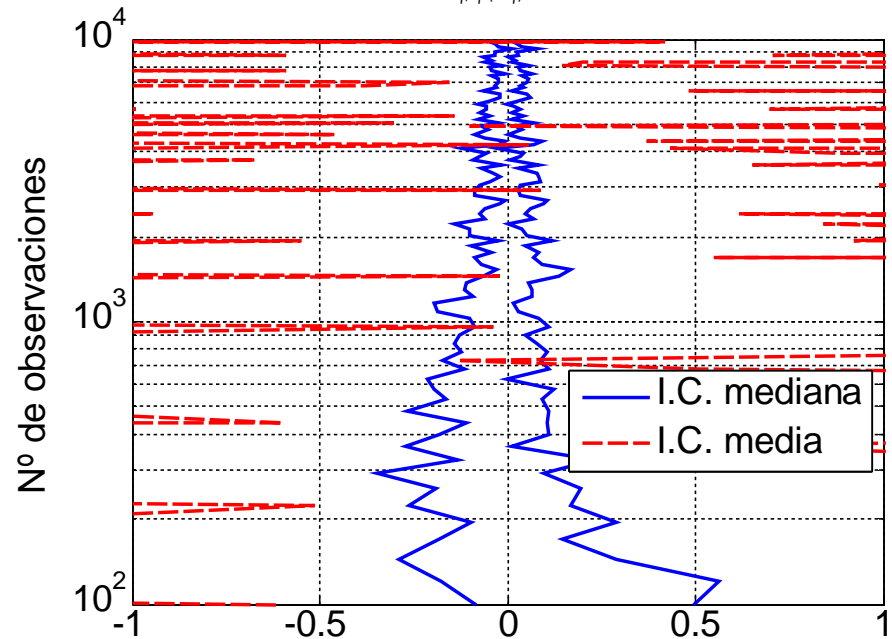

# Intervalos de Confianza

- Ejemplo:  $X_1, \dots, X_n$   $n$  V.A. iid con distribución  $N_{0,1}$ 
  - Dos intervalos de confianza a nivel 0.95
    - Para la media
    - Para la mediana (cuando  $nq$  y  $n(1-q)$  son grandes se puede aproximar la distribución binomial por una normal  $N_{nq, np(1-q)}$  )



# Intervalos de Confianza

- Ejemplo:  $X_1, \dots, X_n$   $n$  V.A. iid con distribución Cauchy $_{0,1}$ 
  - Dos intervalos de confianza a nivel 0.95
    - Para la media (creyéndome equivocadamente que los datos son normales)
    - Para la mediana (cuando  $nq$  y  $n(1-q)$  son grandes se puede aproximar la distribución binomial por una normal  $N_{nq, np(1-q)}$ )





# Intervalos de Confianza



- Sean  $X_1, \dots, X_n$   $n$  V.A. iid y  $x_1, \dots, x_n$  una realización
- Asumamos que queremos calcular un I. de C. de un estadístico  $t(X_1, \dots, X_n)$  pero cuya distribución no sabemos calcular
  - Posible idea: estimar la distribución de  $t(X_1, \dots, X_n)$  a través de su empírica
    - Problema: Tenemos solo una muestra de  $t(X_1, \dots, X_n)$  ( $t(x_1, \dots, x_n)$ )
  - Posible idea 2: si tuviéramos  $R$  muestras de las V.A.  $X_1^r, \dots, X_n^r$  ( $r=1, \dots, R$ ) tales que se distribuyen como  $X_1, \dots, X_n$  podríamos generar  $R$  muestras de  $t(X_1, \dots, X_n)$  evaluando  $t(X_1^r, \dots, X_n^r)$ 
    - Problema: ¿cómo generar las  $R$  muestras  $X_1^r, \dots, X_n^r$ ?
    - Posible respuesta: resampling!
  - Resampling:
    - Una muestra de  $X_1^r, \dots, X_n^r$  se puede generar sorteando **con repetición**  $n$  valores de  $x_1, \dots, x_n$
- Lo que acabamos de describir es básicamente el método de **bootstrap**




# Intervalos de Confianza



- Ejemplo: tengo diez muestras de la duración en meses de un cierto equipo
  - $x = [4 \ 3 \ 0 \ 14 \ 10 \ 2 \ 39 \ 0 \ 9 \ 16]$
  - Asumo que responden al modelo que venimos trabajando hasta ahora (i.e. son la realización de  $n$  V.A. iid  $X_1, \dots, X_n$ )
  - Quisiera un intervalo de confianza para la duración promedio a nivel 0.95
    - Los datos no son normales y además no puedo aplicar la aproximación normal porque no tengo suficientes muestras
    - No me interesa la mediana, quiero la media
  - Genero  $R=999$  muestras con resampling (e.g.  $x_r = [0 \ 4 \ 0 \ 4 \ 9 \ 39 \ 0 \ 0 \ 9 \ 10]$ ), lo que me genera  $R=999$  muestras del promedio (e.g.  $t_r = 7.5$ )
  - Una estimación de un I. de C. a nivel  $\gamma$  es:

$$(t_{((1-\gamma)R/2)}, t_{(\gamma R/2)})$$

i.e. un intervalo conteniendo  $\gamma R$  de las muestras de  $t_r$  (en este caso (3.8,18))



# Intervalos de Confianza



- Algoritmo de bootstrap para intervalos de confianza de un estadístico  $t(X_1, \dots, X_n)$  con  $X_1, \dots, X_n$   $n$  V.A. iid y  $x_1, \dots, x_n$  una realización
- Parámetros:  $r_0$  (e.g.  $r_0=25$ ) y  $\gamma$

```
1:  $R = \lceil 2r_0 / (1 - \gamma) \rceil - 1$ 
2: for  $r = 1, \dots, R$  do
3:   Sean  $(x_1^r, \dots, x_n^r)$  el resultado de sortear
    $n$  valores con reposición de  $(x_1, \dots, x_n)$ 
4:   Sea  $t^r = t(x_1^r, \dots, x_n^r)$ 
5: end for
6:  $(t^{(1)}, \dots, t^{(R)}) = \text{sort}(t^1, \dots, t^R)$ 
7: El intervalo de confianza es  $[t^{(r_0)}, t^{(R+1-r_0)}]$ 
```



# Agenda



- Histogramas y distribuciones empíricas
- (Media, Varianza) y (Mediana, Cuantiles)
- Intervalos de Confianza
- Intervalos de Predicción
- Comentario Finales





# Intervalos de Predicción



- Quizá no se hayan dado cuenta, pero lo que estimamos con bootstrap no fue un intervalo de confianza

- Calculamos un intervalo para el cual:

$$P(u(X_1, \dots, X_n) < t(X_1, \dots, X_n) < v(X_1, \dots, X_n)) \geq \gamma$$

- Un intervalo de confianza hubiera sido por ejemplo un intervalo tal que:

$$P(u(X_1, \dots, X_n) < E\{t(X_1, \dots, X_n)\} < v(X_1, \dots, X_n)) \geq \gamma$$

- Lo primero se denomina **intervalo de predicción**

- Es una medida de la **variabilidad** de  $t(X_1, \dots, X_n)$
- En cambio, un intervalo de confianza es una medida de la **precisión** en mi estimación de  $E\{t(X_1, \dots, X_n)\}$

# Intervalos de Predicción



## ■ Definición:

- Sean  $X_1, \dots, X_n, X_{n+1}$   $n+1$  V.A. (no necesariamente iid)
- Un intervalo de predicción de nivel  $\gamma$  para  $X_{n+1}$  es un intervalo de la forma  $(u(X_1, \dots, X_n), v(X_1, \dots, X_n))$  tal que:

$$P(u(X_1, \dots, X_n) < X_{n+1} < v(X_1, \dots, X_n)) \geq \gamma$$

## ■ Teorema (caso iid):

- Sean  $X_1, \dots, X_n, X_{n+1}$   $n+1$  V.A. iid con distribución  $F()$  tal que  $F()$  tiene densidad
- Sean  $X_{(1)}, \dots, X_{(n)}$  los estadísticos de orden de  $X_1, \dots, X_n$
- Entonces para  $1 \leq j \leq k \leq n$ :

$$P(X_{(j)} \leq X_{n+1} \leq X_{(k)}) = \frac{k - j}{n + 1}$$

- Por lo tanto para  $\alpha \geq 2/(n+1)$  el intervalo  $[X_{((n+1)\alpha/2)}, X_{((n+1)(1-\alpha/2))}]$  es un intervalo de predicción de nivel al menos  $\gamma = 1 - \alpha$



# Intervalos de predicción



- Hay resultados más poderosos que el anterior
  - Por ejemplo si puedo asumir que los datos son iid y además normales
- De todas formas es importante quedarse con el significado del intervalo de predicción
  - Si realizo muchas realizaciones de  $X_{n+1}$ , ésta estará al menos  $\gamma$  veces dentro del intervalo de predicción
- Caso iid
  - Las  $X_i$  me ayudan a predecir  $X_{n+1}$
  - ¿Contradicción?



# Agenda



- Histogramas y distribuciones empíricas
- (Media, Varianza) y (Mediana, Cuantiles)
- Intervalos de Confianza
- Intervalos de Predicción
- Comentario Finales





# Comentarios Finales



- Todas las técnicas mencionadas necesitan “iid-ismo”
- ¿Cómo hago que los datos sean iid?
  - Si controlo el experimento (como en una simulación) está en mí lograr que los datos sean iid
    - Por ejemplo, si es una simulación tengo que generar los resultados mediante tiradas independientes en el generador aleatorio
    - Si por ejemplo estoy midiendo cuánto demora un servidor ante un conjunto de pedidos, tengo que elegir en cada experimento el pedido al azar con reposición
  - Si NO controlo el experimento (e.g. son medidas de campo) difícilmente los datos sean iid
    - Por lo general aleatorizando las medidas se corrige el problema
    - Ejemplo: medidas del tiempo de atención de pedidos http en un servidor web
      - Probablemente los tiempos de atención estén muy correlacionados en el tiempo
      - Puedo generar un conjunto nuevo tomando cada medida con probabilidad  $p$  (si sigue sin ser independientes genero uno nuevo con una  $p$  menor que la anterior)





# Comentarios Finales



- ¿Cómo verifico que mis datos hayan sido generadas por V.A. iid?
  - Lag-Plots
    - Una gráfica de  $(x_i, x_{i+k})$  para varios valores de  $k$
    - Si son independientes no se deberían ver tendencias en las curvas
  - Tests
    - Las próximas clases
- ¿Qué pasa si calculo un intervalo de confianza pensando que fueron generadas por una V.A. iid y no es verdad?
  - Si los datos no son independientes y el calculo asume que sí, el intervalo de confianza resultante va a ser más pequeño de lo que un intervalo correcto sería





# Comentarios Finales



## ■ Hipótesis para el intervalos de confianza de la media

- ¿Cómo saber si mi  $n$  es suficientemente grande?
- ¿Cómo saber si  $F()$  tiene esperanza y varianza finitas?
- Lo que se requiere en realidad es que

$$\frac{\bar{X}_n - E\{X_1\}}{\sigma/\sqrt{n}} \sim N_{0,1}$$

- Tengo solo una muestra del promedio
  - ¿Cómo obtengo su distribución?
  - Bootstrap!
  - Verifico que tenga distribución normal (sin importar la media o la varianza)

## ■ Ejemplo de la duración de los productos

( $x = [4 \ 3 \ 0 \ 14 \ 10 \ 2 \ 39 \ 0 \ 9 \ 16]$ )

