

# Simulación

Dpto. Ingeniería Industrial, Universidad de Chile

IN47B, Ingeniería de Operaciones

30 de septiembre de 2013

# Contenidos

- 1 Introducción
- 2 Eventos discretos
- 3 Modelación Implementación
- 4 Analizando Resultados
- 5 Otros temas

# ¿Qué es Simulación

- Representación de un *sistema* en un computador.
- Intenta emular el funcionamiento de un *sistema*.
- Usado para evaluar *numéricamente* el comportamiento de sistemas bajo ciertas condiciones.



# Ejemplo:

## Atención de clientes en un Banco

- El *sistema* puede ser el conjunto de clientes, cajeros, colas, y procedimientos predefinidos (FIFO, etc.) que describen la operación.
- Las *variables de estado* en este caso son el número de clientes en cada cola, el número de cajeros, y el estado de cada cajero (ocupado/desocupado).,

# Sistemas Discretos y Continuos

## Sistema Discreto

Un Sistema se dice *Discreto* si sus variables de estado cambian sus valores en un conjunto numerable de instantes de tiempo (Ej.: sistemas de colas).

## Sistema Continuo

Un Sistema se dice *continuo* si sus variables de estado cambian continuamente en el tiempo (Ej.: El sistema solar).

# Sistemas Dinámicos y Estáticos

## Sistema Estático

Un Sistema se dice *estático* si el tiempo en el no juega ningún rol (Ej.: Simulaciones tipo montecarlo, estimar  $\pi$ ).

## Sistemas Dinámicos

Un Sistema se dice *dinámico* si este evoluciona a medida que el tiempo pasa.

# Sistemas Determinísticos y Estocásticos

## Sistema Determinístico

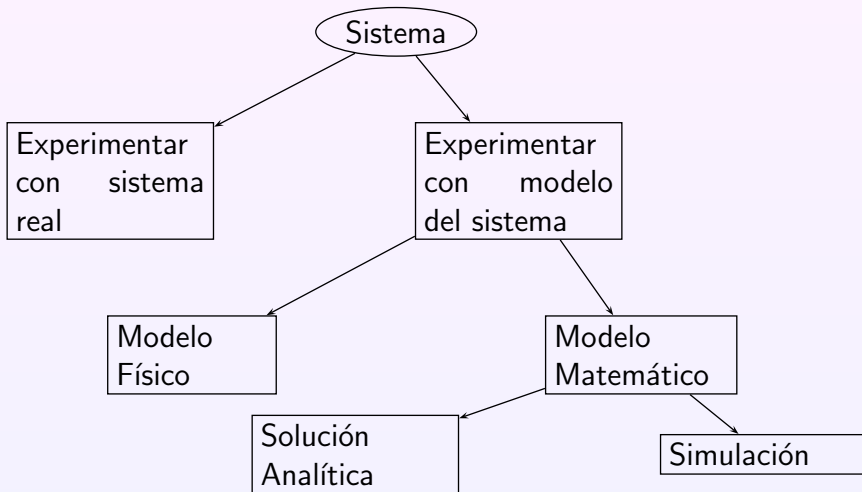
Un Sistema se dice *determinista* si su evolución temporal esta definida completamente por las condiciones iniciales del mismo (Ej.: Sistema de ecuaciones diferenciales).

## Sistema Estocástico

Un Sistema se dice *estocástico* si tiene componentes descritos en términos probabilísticos, o donde existe incertidumbre en la entrada o en el proceso mismo del sistema (Ej.: Sistema de colas en un banco).



# Formas de estudiar un Sistema



# Simulación de eventos discretos

- Se asume modelo dinámico que cambia variables de estado una cantidad numerable de veces.
- Un evento es un acontecimiento instantáneo que puede cambiar el estado del sistema.
- Ejemplo M/M/1:
  - Variables de estado son largo de cola (tiempo de llegada?), y estado del servidor.
  - Dado lo anterior, existen esencialmente dos tipos de *eventos*: llegada de clientes, y salida de clientes.
- En general, podríamos considerar eventos que no cambian las variables de estado de un sistema:
  - Un evento que marca el fin de la simulación.
  - Cambio en las reglas de operación del sistema.

# Mecanismos de avance de tiempo:

- Necesitamos conocer el tiempo *simulado*.
- Tiempo interno del sistema se llama *reloj de simulación*.

## Incremento Fijo

Se asume que los eventos ocurren en el conjunto

$$T_{sim} \in \{t_o, t_o + \Delta, t_o + 2\Delta, \dots\}.$$

## Avanzar al siguiente evento

Asume que los eventos pueden ocurrir en cualquier momento ( $T_{sim} \in \mathbb{R}$ ), pero relacionados a un evento ( $\|T_{sim}\| \leq \aleph_o$ ).

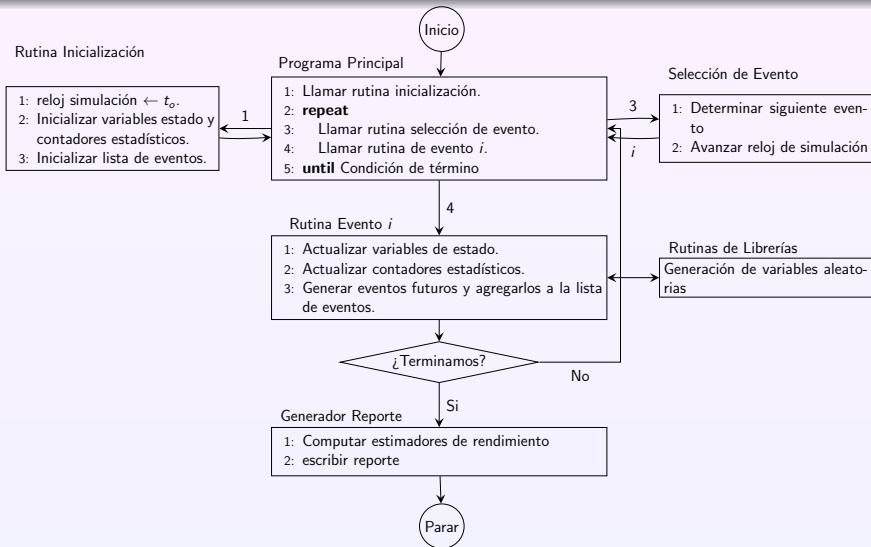
# Componentes y Organización

- **Variables de Estado:** Conjunto de variables de estado que describen el sistema en algún momento.
- **Reloj de simulación:** Variable que guarda el tiempo en el sistema.
- **Lista de eventos:** Lista (parcial) de eventos a realizarse en el futuro.
- **Contadores Estadísticos:** Variables que guardan los indicadores relevantes del sistema.
- **Inicialización:** Subrutina que inicializa modelo en  $t_o$ .
- **Selección de evento:** Subrutina que determina siguiente evento a realizarse.

# Componentes y Organización

- **Rutinas de evento:** Subrutina que actualiza el sistema cuando un evento ocurre.
- **Rutinas Auxiliares:** Generación de variables aleatorias, etc.
- **Generador de Reporte:** Subrutina que computa estimadores de las medidas de desempeño del sistema (basándose en los contadores estadísticos) cuando la simulación termina.
- **Programa Principal:** Programa que primero lee parámetros de entrada, inicializa el sistema, y después llama a la rutina de selección de eventos hasta el término de la simulación, y finalmente llama a la rutina de reporte.

# Flujo de un programa Típico de Simulación



# ¿Por que escribir software de simulación?

- Conocer como funcionan internamente todos los softwares de simulación ayuda a evitar errores conceptuales en su uso.
- En simulaciones complejas muchas veces es necesario programar algunas partes de la simulación para interactuar con softwares comerciales.
- Lenguajes de programación generales estan siempre disponibles, y son de bajo costo.
- Muchas simulaciones comerciales aun se programan en lenguajes generales.

# Generando Variables Aleatorias:

- En general asumiremos que existe un generador de numeros pseudo-aleatorios  $f()$  uniforme  $(0, 1)$ .
- Dada una distribución acumulada  $F(x) = \mathbb{P}(X \leq x)$ , generaremos un valor aleatorio usando la fórmula  $x = F^{-1}(f())$
- Cuidado con funciones aleatorias por defecto, en general de mala calidad.
- ¿Cuándo funciona?
  - Si  $F$  es estrictamente creciente.
  - Con cuidado podemos hacerlo si  $F$  es discreta, o si tiene *saltos*




# Simulación de un M/M/1

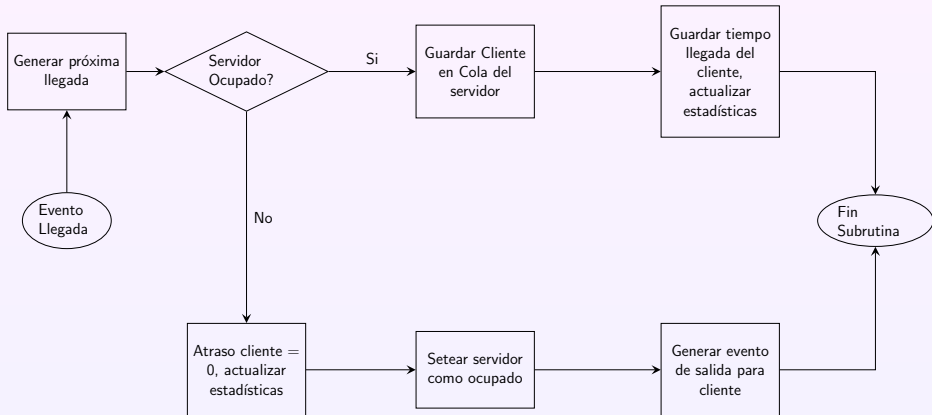
## Eventos

- Llegada de un Cliente  $F(x) = 1 - e^{-\frac{x}{\beta_1}}$ .
- Cliente Termina de ser atendido  $F(x) = 1 - e^{-\frac{x}{\beta_2}}$ .
- Cliente Comienza a ser atendido?

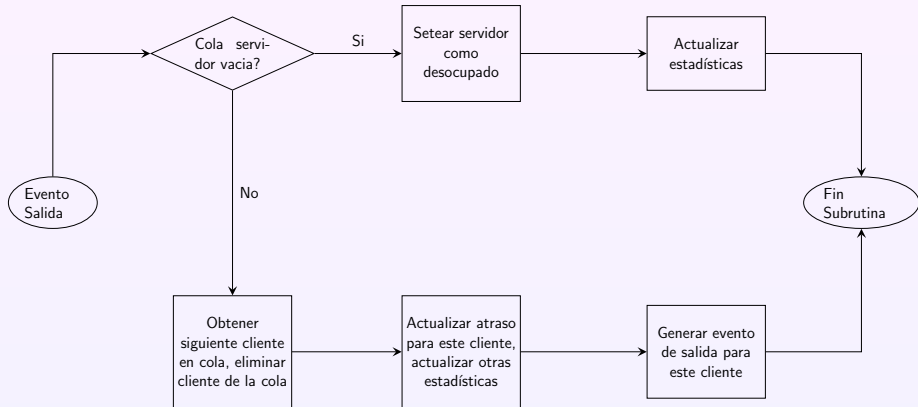
## Grafo de Eventos



# Lógica llegada de cliente



# Lógica salida de cliente

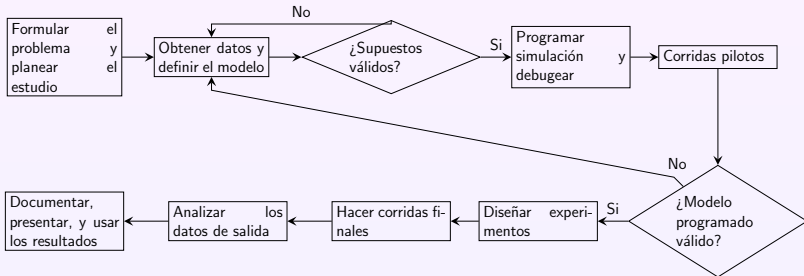


# Evaluando política de inventario

- Consideremos una política de inventario  $(S, s)$  de revisión mensual, con costos por mantener items en bodega y back-orders.
- Demandas espaciadas  $iid \approx \exp(0,1)$ , cantidades  $\{1, 2, 3, 4\}$  con probabilidades  $\{1/6, 1/3, 1/3, 1/6\}$ .
- Cuando una orden se coloca, el tiempo de llegada es distribuido como  $U[1/2, 1]$ , y el costo es función de la cantidad demandada.

## Pasos de un buen estudio de simulación

# Vista General



# Formular el problema y planear estudio

- Problema presentado por una unidad.
  - Problema puede estar mal definido, o en términos cualitativos.
  - Proceso Iterativo es necesario
- Varias reuniones con director proyecto, experto de simulación, experto en el sistema.
  - Definir objetivos del estudio.
  - Definir preguntas específicas a responder.
  - Definir medidas numéricas para comparar diferentes configuraciones.
  - Alcance del modelo.
  - Diferentes configuraciones a probar.
  - Tiempo del estudio y recursos necesarios.
- Seleccionar el software a usar.

# Recoger Datos del Sistema

- Recoger información sobre estructura y reglas de operación del sistema.
  - Ningún individuo es suficiente.
  - Personas con conocimiento equivocado del sistema (buscar expertos reales).
  - Procedimientos pueden no estar formalizados.
- Recoger datos para definir parámetros del sistema y distribuciones de entrada.
- Formalizar información anterior en un documento de supuestos.
- Recoger datos sobre el desempeño del sistema real.

# Recoger Datos del Sistema

- Escoger nivel de detalle del sistema.
  - Objetivos del proyecto.
  - Métricas a utilizar.
  - Datos disponibles.
  - Problemas de credibilidad.
  - Opinión de los expertos del sistema.
  - Restricciones de tiempo/presupuesto.
- Empezar con un modelo simplificado y refinarlo a medida que sea necesario.
- Interactuar con el director del proyecto y expertos del sistema regularmente.



# ¿Son los Supuestos Válidos?

- Realizar una revision del documento de supuestos con los expertos del sistema y con el director del proyecto.
  - Asegurar que supuestos son correctos y completos.
  - Ayudar a la interacción entre miembros del equipo.
  - Incrementar el sentido de propiedad del modelo en el equipo.
  - Debería hacerse antes de comenzar a programar.

## Construir un programa y verificarlo

- Programar en un lenguaje general (C,C++,Java,C#) o en un software de simulación (Arena, Extend, Flexsim, ProModel).
  - Lenguajes generales tienen la ventaja de que usualmente uno es conocido.
  - Ofrecen control absoluto del programa.
  - Son mucho mas baratos de comprar (Licencias).
  - Pueden resultar en tiempos de ejecucion menores.
  - Lenguajes de simulacion resultan en menores tiempos de programación
    - Proveen de interfaces gráficas (Atractivas para gerencia).
- Debugear el programa.

# Corridas Piloto, ¿Es el modelo programado Válido?

- Ejecutar corridas pilotos del programa
- Comparar desempeño real del sistema con sistema simulado.
- Revisar consistencia de resultados con expertos del sistema real y con director proyecto.
- Realizar análisis de sensibilidad, identificando aspectos del sistema que necesitan mayor nivel de detalle o cuidado en el modelo.

# Diseño de Experimentos

- Para cada configuración de interes especificar:
  - Largo de cada corrida de simulación.
  - Período transiente de cada corrida (si necesario).
  - Número de simulaciones independientes a realizar, para así definir los correspondientes intervalos de confianza.

# Corridas Finales, Análisis de Resultados

- Ejecutar corridas principales.
- Objetivos principales en el análisis son:
  - Determinar desempeño absoluto de cada configuración analizada.
  - Comparar configuraciones alternativas en forma comparativa (análisis de tipo pareto).

# Documentar, presentar, y usar resultados

- Documentar supuestos utilizados.
- Documentar código del programa.
- Documentar creiterios de intervalos de confianza, etc.
- Presentar Resultados:
  - Uso de animaciones para presentar modelo a audiencia amplia.
  - Discutir proceso de validación de sistema.
  - Resultados se usarán en la medida de que sean validos y creibles.

# Supuestos Generales

- Asumimos que existe un generador de números aleatorios uniforme.
- Nótese que estos no son continuos, tienen entre 32 o 56 bits de resolución.
- Diferencias menores a  $10^{-9,6}$  o  $10^{-16,8}$  no pueden observarse (recomendado: no menos de  $10^{-6}$ )
- Asumimos que aleatoriedad del generador es buena.
- Asumimos que el generador es *eficiente*.

# Transformación Inversa

- Dado  $U \sim U(0, 1)$ ,  $X \sim F$  probabilidad acumulada, retornar  $X = F^{-1}(U)$ .
- Ejemplo:  $X \sim \exp(\beta)$  entonces
 
$$F(x) = \begin{cases} 1 - e^{-x/\beta} & x \geq 0 \\ 0 & \text{si no} \end{cases}$$
- $F^{-1}(u) = -\beta \log(1 - u)$ .
- Requiere generar un solo número aleatorio.
- Extendible a  $F$  no continuas, con saltos numerables.
- Más generalmente  $X = \min\{x : F(x) \geq U\}$ .
- Si  $F^{-1}$  no se conoce, método numérico es necesario.
- Fácil producir distribuciones truncadas.



# Compocición

- Aplicable a compocición convexa de variables aleatorias.
- $F(x) = \sum_{i \in \mathbb{N}} p_i F_i(x)$ ,  $p_i \geq 0$ ,  $\sum_{i \in \mathbb{N}} p_i = 1$ .
- Generar número  $j$  tal que  $P(j) = p_j$ .
- Retornar  $X$  con distribución  $F_j$ .
- Ejemplo:  $X \sim Trap(a)$ , donde
 
$$f(x) = \begin{cases} a + 2(1-a)x & 0 \leq x \leq 1 \\ 0 & \text{si no} \end{cases}.$$
- $f(x) = aI_{[0,1]}(x) + (1-a)2xI_{[0,1]}(x)$ .
- Requiere sólo un números aleatorio y generar sub-variable aleatoria.

# Convolución

- Aplicable a variables aleatorias que son sumas de otras variables aleatorias independientes.
- $X = \sum_{i=1}^n Y_i.$
- Generar  $Y_i$  con la distribución apropiada.
- Retornar  $X = \sum_{i=1}^n Y_i.$
- Ejemplo:  $X \sim \text{m-Erlang}(\beta)$
- $X = \sum_{i=1}^m \exp(\beta/m).$

# Aceptar/Rechazar

- Tenemos  $X$  con densidad  $f(x)$  a soporte acotado  $S$ .
- Definimos  $c = \max\{f(x) : x \in S\}$ .
- Generar  $x$  uniformemente en  $S$ .
- generar  $Y$  uniformemente en  $[0, c]$
- Retornar  $x$  si  $Y \leq f(x)$ , si no, generar nuevamente  $x, Y$ .
- Útil cuando otros métodos son difícil de implementar.
- Dependiendo de  $f$  puede requerir muchas generaciones de números aleatorios.

# Definiciones

- $\mathbb{E}(X) = \int_{Dom(X)} x \cdot f(x) \cdot dx.$
- $\text{Var}(X) = \mathbb{E}(X^2) - \mathbb{E}(X)^2 = \mathbb{E}((X - \mathbb{E}(X))^2).$
- $\mathbb{Cov}(X, Y) = \mathbb{E}((X - \mathbb{E}(X))(Y - \mathbb{E}(Y))) = \mathbb{E}(XY) - \mathbb{E}(X)\mathbb{E}(Y).$
- Si  $X, Y$  son independientes  $\mathbb{Cov}(X, Y) = 0.$
- La reciproca no es cierta.
- $\mathbb{Cor}(X, Y) = \frac{\mathbb{Cov}(X, Y)}{\sqrt{\text{Var}(X)\text{Var}(Y)}}.$

# Estimadores

- Consideramos  $X_i : i = 1, \dots, n$  una muestra de  $X$ .

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

- $\bar{X}(n)$  es un estimador no sesgado de  $\mathbb{E}(X)$ .

$$S^2(n) = \frac{\sum_{i=1}^n (X_i - \bar{X}(n))^2}{n - 1}.$$

- $S^2(n)$  es un estimador no sesgado de  $\text{Var}(X)$ .

$$\text{Var}(\bar{X}(n)) = \frac{\text{Var}(X)}{n}.$$

# Teorema Central del Límite

- Consideramos  $\{X_i\}_{i \in \mathbb{N}}$  variables aleatorias iid con  $\mathbb{E}(X_i) = \mu$  y  $\text{Var}(X_i) = \sigma^2$ .
- Definimos  $Z_i = \frac{\bar{X}(n) - \mu}{\sqrt{\frac{\sigma^2}{n}}}$ .
- Llamamos  $F_n(z) = \mathbb{P}(Z_n \leq x)$

## Teorema Central del Límite

$$\lim_{n \rightarrow \infty} F_n(z) = \Phi(z)$$

Donde  $\Phi(z) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^z e^{-y^2/2} dy$ .

# Teorema Central del Límite

- Básicamente el TCL dice que  $Z_n \sim \mathcal{N}(0, 1)$  cuando  $n$  es grande.
- Otro problema es que  $Z_n$  esta definido en términos de  $\sigma^2$ .
- Definimos  $t_n = \frac{\bar{X}(n) - \mu}{\sqrt{\frac{S^2(n)}{n}}}$ .
- Se puede demostrar que  $t_n$  tambien converge a una  $\mathcal{N}(0, 1)$ .
- De ahí podemos decir que  $\mathbb{P}(-z_{1-\alpha/2} \leq t_n \leq z_{1-\alpha/2}) \approx 1 - \alpha$  para  $n$  suficientemente grande.

# Intervalos de Confianza

- De lo anterior, podemos concluir que

$$\mathbb{P}(l(n) \leq \mu \leq u(n)) = 1 - \alpha$$

para  $n$  suficientemente grande, donde

$$l(n) = \bar{X}(n) - z_{1-\alpha/2} \sqrt{\frac{S^2(n)}{n}}$$

y

$$u(n) = \bar{X}(n) + z_{1-\alpha/2} \sqrt{\frac{S^2(n)}{n}}$$



# Intervalos de Confianza

- ¿Qué pasa si  $X_i \sim \mathcal{N}(0, 1)$ ?
- En ese caso  $t_n \sim$  T-student de  $n - 1$  grados de libertad.
- Intervalo de confianza exacto esta dado por  

$$\overline{X}(n) \pm t_{n-1, 1-\alpha/2} \sqrt{S^2(n)/n}.$$
- Se tiene que estos intervalos son mayores a considerar que  
 $t_n \sim \mathcal{N}(0, 1).$
- En general, debemos preguntarnos ¿Qué significa  $n$  suficientemente grande?.

# Cobertura Real

- Consideramos intervalos de confianza derivados de la T-student.
- Distinto número de muestras  $n = 5, 10, 20$ , y  $40$ .
- Consideramos  $X_i$  iid con distintas distribuciones.
- Comparamos cobertura real del intervalo estimado a  $90\%$  sobre  $500$  repeticiones.

Dist	$\nu$	n=5	n=10	n=20	n=40
Normal	0.00	0.910	0.902	0.898	0.900
Exponencial	2.00	0.854	0.878	0.870	0.890
Chi <sup>2</sup>	2.83	0.810	0.830	0.848	0.890
Lognormal	6.18	0.758	0.768	0.842	0.852
Hiper-exp	6.43	0.584	0.586	0.682	0.774

# Midiendo Simetría de Distribuciones

- ¿Qué es  $\nu$ ?
- $$\nu = \frac{\mathbb{E}((X - \mu)^3)}{\sigma^3}.$$
- $\nu$  es una medida de simetría de la distribución.
- Simetría de una distribución es un factor importante al momento de determinar cuando  $n$  es *suficientemente grande* en el contexto del TCL.
- En general, No deberíamos mirar solamente a  $\mu$ , si no que también a  $\sigma^2$  cuando describimos una distribución.

# ¿Cómo obtenemos variables iid?

- Consideremos un sistema de simulación donde hay sólo una medida de desempeño, que es reportada en distintos puntos  $J$  durante la simulación.
- Suponemos además que ejecutamos  $n$  corridas independientes de la simulación, esto define  $X_{i,j}$  con  $i = 1, \dots, n$  y  $j \in J$ .
- Asumiendo buenos números aleatorios, podemos considerar  $\{X_{i,j}\}_{i=1}^n$  como variables iid.
- Desafortunadamente  $\{X_{i,j}\}_{j \in J}$  en la práctica no son independientes, de hecho, usualmente, tienen correlación positiva.

# Algunos Ejemplos prácticos

- Consideramos un modelo M/M/1 con tasa de ocupación  $\rho = ,9$ .
- Tratamos de estimar promedio de lso 25 primeros atrasos.
- Computamos 500 intervalos de confianza basados en 5,10,20 y 40 replicaciones.
- Comparamos proporción de intervalos *correctos* y su ancho medio.

# M/M/1, estimando $d_{25}$

n	cobertura	intervalo 90 %	medio ancho
5	0.880	$\pm 0.024$	0.67
10	0.864	$\pm 0.025$	0.44
20	0.886	$\pm 0.023$	0.30
40	0.914	$\pm 0.021$	0.21

# Tiempo medio a Falla

- Sistema con tres componentes.
- Sistema funciona mientras componente 1 funcione y componente 2 o componente 3 funcionen.
- Tiempo falla  $G = \min\{G_1, \max\{G_2, G_3\}\}$ ,  $G_i$  es Weibull(0.5,1).

n	cobertura	intervalo 90 %	medio ancho
5	0.708	$\pm 0.033$	1.16
10	0.750	$\pm 0.032$	0.82
20	0.800	$\pm 0.029$	0.60
40	0.840	$\pm 0.027$	0.44

# El Problema

- En general queremos comparar distintas configuraciones.
- Significa estimar parametros y compararlos.
- ¿Cuándo podemos decir que son distintos?

## Ejemplo

Compararemos un sistema  $M/M/1$  con un sistema  $M/M/2$ .  
 En sistema  $M/M/1$  llegadas son 10 por unidad de tiempo, y atendemos 11 clientes por minutos. En sistema  $M/M/2$  llegadas son 10 por unidad de tiempo, y cada servidor atiende 5.5 clientes por minutos.



# Comparando estimadores de $\mu$


- Supongamos que ambas configuraciones cuestan lo mismo.
- Escoger sólo dependa de calidad de servicio.
- Medimos calidad de servicio como tiempo espera promedio.

## Primer reflejo

Supongamos que tenemos un *especialista* que sabe de simulación. Simula ambos sistemas, y computa una estimación de  $\mu$  para ambos sistemas con  $k$  corridas independientes. El decide escoger el sistema con mejor tiempo de espera *estimada*



## Comparando Distintas Configuraciones

## ¿Cómo nos va?



# Otro Enfoque

- Un mejor enfoque sería compupar intervalos de confianza para ambos  $\mu$ .
- Habria que alanzar un nivel donde ambos intervalos no se overlapan.




# Algunas Observaciones

- El enfoque anterior funciona.... pero
- Típicamente requiere un número de replicaciones altas.
- Sufre de los problemas de no-simetria de las distribuciones subjacentes.
- El problema anterior podríamos solucionarlo.
- Considerando diferencia de los estimadores.
- Analizamos  $Z_n = X_n - Y_n$ .
- $Z_n$  tiende a tener una alta simetria.
- Decimos que configuraciones son distintas si 0 no esta en intervalo de confianza.

## Comparando Distintas Configuraciones

## ¿Cómo nos va con este enfoque?



# Podemos Mejorar?

- Otra forma de comparar sistemas o configuraciones.
- Exacerbar diferencias en lo sistemas.
- Comparar bajo situaciones de stress del sistema.
- Ello conlleva a diferencias más sustanciales en los estadísticos.

# Caso de múltiples configuraciones:

## Comparación con Standard:

- Elegimos una configuración base  $X^0$ .
- Comparamos  $k$  configuraciones  $X^i : i = 1, \dots, k$ .
- Computamos intervalos de confianza de  $X^0 - X^i : i = 1, \dots, k$  a nivel  $1 - \alpha/k$ .
- Obtenemos Intervalo de confianza global de  $1 - \alpha$ .

# Caso de múltiples configuraciones:

## Comparacion todos los pares:

- Dado  $k$  configuraciones  $X^i : i = 1, \dots, k$ .
- Comparamos todos los pares  $i, j$ .
- Computamos intervalos de confianza para  $X^i - X^j : i, j = 1, \dots, k, i \neq j$  de nivel  $1 - \alpha/k(k - 1)$ .
- Obtenemos Intervalo de confianza global de  $1 - \alpha$ .




# ¿Qué comparamos cuando comparamos?

- Típicamente comparamos un sistema bajo distintas reglas de operación.
- Los enfoques anteriores comparar ciegamente.
- Llevan a una alta varibilidad.
- ¿Qué queremos realmente?
- Comparar sistema en condiciones lo más cercanas posibles.
- En nuestro ejemplo, ¿qué significaría esto?
- Sistema bajo *misma* demanda.
- Notese que ahora correlación de  $X$  e  $Y$  no es cero.
- Lleva a menores varianzas.
- requiere menos replicaciones para resultados confiables.

# Impacto en Ejemplo



# Impacto en Ejemplo



# ¿Qué quedó afuera?

- Generar variables aleatorias correlacionadas.
- Validando supuestos del modelo
  - Habría que hacer análisis estadísticos.
- Case de sistemas en estado estacionario.
- Análisis de sistemas oscilantes.
- Buscando buenos generadores de números aleatorios.