

# Estimación Bayesiana en modelos farmacocinéticos

Alejandro Nieto Ramos

Asesores: Dr. Gabriel Núñez A y Dr. Héctor Morales B.

Febrero de 2017

Maestría en Ciencias Matemáticas Aplicadas e Industriales


# Introducción

## Objetivo

Presentar una metodología estadística para realizar inferencia bayesiana en sistemas de ecuaciones diferenciales ordinarias que modelen la cinética de fármacos en el organismo humano utilizando modelos de dos compartimentos.

# Problema

## Perfiles de concentración de teofilina



9 pacientes

11 mediciones (periodo de 25 h)

# Modelo de dos compartimentos

## Esquema

- ▶  $x_1$  estómago;  $x_2$  sangre
- ▶  $\alpha, \beta$  tasas desconocidas relacionadas con la cinética
- ▶  $V$  volumen total de la sangre;  $D$  dosis administrada al inicio del experimento



## Sistema de EDO

$$\begin{aligned}x_1'(t) &= -\alpha x_1(t), & x_1(0) &= D \\x_2'(t) &= \frac{\alpha}{V} x_1(t) - \beta x_2(t), & x_2(0) &= 0.\end{aligned}$$

## Solución analítica

$$x_1(t|\alpha) = D e^{-\alpha t}, \quad x_2(t|\alpha, \beta) = \frac{D}{V} (e^{-\beta t} - e^{-\alpha t})$$

# Comparación



$$\text{Solución } x_2(t|\alpha, \beta) = 10(e^{-\beta t} - e^{-\alpha t}).$$

# Formulación del modelo estadístico

## Sistema de EDO

$$x'(t) = f(x, t, \theta)$$

$x(t) \in \mathbb{R}^d$  para cada  $t \in [0, T]$ ,  $f$  conocida y  $\theta \in \mathbb{R}^q$ .

## Modelo estadístico

$$y_{ijk} = x_j(t_{ijk}|\theta) + \epsilon_{ijk}$$

- ▶  $y_{ijk}$  es la  $k$ -ésima observación de la  $i$ -ésima unidad experimental en la  $j$ -ésima función de estado registrada en el tiempo  $t_{ijk}$
- ▶  $j \in C \subset \{1, 2, 3, \dots, d\}$
- ▶  $N$  número de unidades experimentales
- ▶  $n_{ij}$  número de observaciones de la  $i$ -ésima unidad experimental en la  $j$ -ésima función de estado
- ▶  $\epsilon_{ijk} \sim N(0, \tau_j^{-\frac{1}{2}} x_j(t_{ijk}|\theta)), \tau_j > 0$

# Estrategias de la estimación de parámetros

$D$  conjunto de datos,  $M$  modelo y  $\theta$  vector de parámetros

$$\text{Verosimilitud} \equiv p(\theta|D, M)$$

## Máxima Verosimilitud

$$\theta_{MV} = \arg \min_{\theta_i} p(\theta_i|D, M)$$

## Máximo a posteriori

Considerar a  $\theta$  como variable aleatoria con distribución  $p(\theta)$

$$p(\theta|D) = \frac{p(D|\theta)p(\theta)}{p(D)} \quad (\text{Teorema de Bayes})$$

$$\underbrace{p(\theta|D)}_{\text{d. a posteriori}} \propto \underbrace{p(D|\theta)}_{\text{verosimilitud}} \cdot \underbrace{p(\theta)}_{\text{d. a priori}} .$$

# Estimación bayesiana de los parámetros del sistema

Regresando al problema,

$$p(\theta, \tau | D) \propto p(D | \theta, \tau) p(\theta, \tau)$$

donde

$$p(y | \theta, \tau) = \prod_{i=1}^N \prod_{j \in C} \prod_{k=1}^{n_{ij}} \frac{\sqrt{\tau}}{\sqrt{2\pi} x_j(t_{ijk} | \theta)} e^{-\frac{\tau}{2} \left[ \frac{y_{ijk} - x_j(t_{ijk} | \theta)}{x_j(t_{ijk} | \theta)} \right]^2},$$

y  $p(\theta, \tau)$  se propone de acuerdo al contexto del problema.

Para obtener una muestra de  $p(\theta, \tau | D)$  se usará un **Método de Monte Carlo via cadenas de Markov**: el algoritmo de **Metropolis**.



# Algoritmo de Metropolis

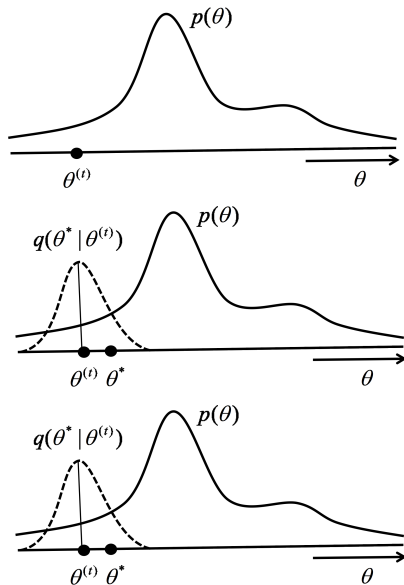
Dada  $\theta^{(t)}$ ,

1. Generar  $\theta^* \sim q(\theta|\theta^{(t-1)})$
2. Tomar  $\theta^{(t)} = \begin{cases} \theta^* & \text{con probabilidad } \alpha, \\ \theta^{(t)} & \text{con probabilidad } 1 - \alpha, \end{cases}$

donde

$$\alpha = \min \left( 1, \frac{p(\theta^*)}{p(\theta^{(t-1)})} \right).$$

# Algoritmo de Metropolis



# Aplicación de la metodología

## Suposición

Los perfiles de concentración se modelan con un modelo de dos compartimentos

Se estimarán:  $(\alpha, \beta, \tau)$  y  $x_2(t|\alpha, \beta)$  dados  $\{(y_{ik}, t_{ik})\}$ ,  $N = 9$ ,

$n_i = n = 11$ ,

donde

$$y_{ik} = x_2(t_{ik}|\alpha, \beta) + \epsilon_{ik}$$

$\epsilon_{ik} \sim N(0, \tau^{-\frac{1}{2}} x_2(t_{ik}|\alpha, \beta))$  independientes


$$p(y|\alpha, \beta, \tau) = \prod_{i=1}^9 \prod_{k=1}^{11} \frac{\sqrt{\tau}}{\sqrt{2\pi} x_2(t_{ik}|\alpha, \beta)} e^{-\frac{\tau}{2} \left[ \frac{y_{ik} - x_2(t_{ik}|\alpha, \beta)}{x_2(t_{ik}|\alpha, \beta)} \right]^2}.$$

# Aplicación de la Metodología

## Distribución inicial

$$P(\alpha, \beta, \tau) = P(\alpha; a_\alpha, b_\alpha)P(\beta; a_\beta, b_\beta)P(\tau; a_\tau, b_\tau)$$

donde  $P(x; a, b) = \frac{1}{\Gamma(a)b^a}x^{a-1}e^{-\frac{x}{b}}\mathbb{I}_{(0,\infty)}(x)$ .



# Aplicación de la Metodología

$$p(\alpha, \beta, \tau | y) \propto \left[ \prod_{i=1}^9 \prod_{k=1}^{11} x_2(t_{ik} | \alpha, \beta) \right]^{-1} \tau^{\frac{9 \cdot 11}{2}} e^{-\frac{1}{2} \tau \sum_{i=1}^9 \sum_{k=1}^{11} \left[ \frac{y_{ik} - x_2(t_{ik} | \alpha, \beta)}{x_2(t_{ik} | \alpha, \beta)} \right]^2} \\ \cdot P(\alpha; 4, 1) P(\beta; 1, 2) P(\tau; 2, 160)$$


Para simplificar el muestreo,

$$p(\alpha, \beta | y) = \int_0^{\infty} p(\alpha, \beta, \tau | y) d\tau \\ \propto \left[ \prod_{i=1}^9 \prod_{k=1}^{11} 10(e^{-\beta t_{ik}} - e^{-\alpha t_{ik}}) \right]^{-1} \alpha^{4-1} e^{-\alpha - \frac{\beta}{2}} \\ \cdot \underbrace{\left[ \left( \frac{1}{2} \sum_{i=1}^9 \sum_{k=1}^{11} \left[ \frac{y_{ik} - 10(e^{-\beta t_{ik}} - e^{-\alpha t_{ik}})}{10(e^{-\beta t_{ik}} - e^{-\alpha t_{ik}})} \right]^2 + \frac{1}{160} \right)^{-1} \right]^{\left( \frac{9 \cdot 11}{2} + 2 \right)}}_{B_{\tau}(\alpha, \beta) A_{\tau}(\alpha, \beta)}$$


$$P(\tau | \alpha, \beta) \sim \text{Gamma}(B_{\tau}(\alpha, \beta), A_{\tau}(\alpha, \beta))$$

# Resultados


### Histogram of alfa



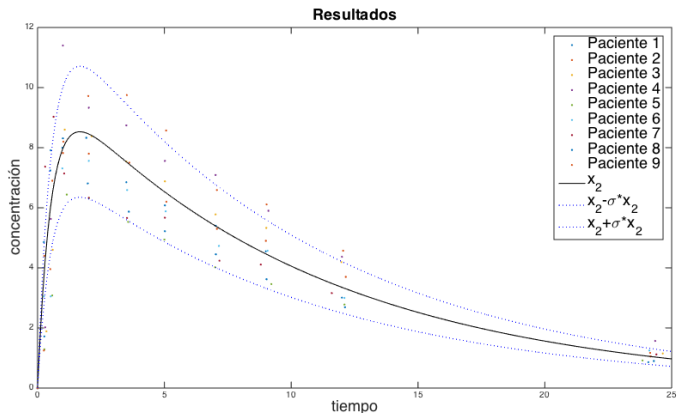
### Histogram of beta



### Histogram of tau



# Resultados



Parámetros	$\alpha$	$\beta$	$\tau$
moda	1.887278	0.09539162	15.3086