# Fundamentos de Inferencia Bayesiana 2017

# Operacionales

- Horario
- Programa
- Evaluación
- Puntos, licenciatura/doctorado
- Correlativas
- ¿Otras?

# Bibliografía

- Gelman *et al.* Bayesian Data Analysis
- MacKay Information Theory, Inference, and Learning Algorithms
- Jaynes
   Probability Theory: The Logic of Science
- Barber
   Bayesian Reasoning and Machine Learning
- Hacking An Introduction to Probability and Inductive Logic
- Wagenmakers & Lee
   A Course in Bayesian Graphical Modeling for Cognitive Science
- Marr, Anderson, ...

#### Experimento mental (gedankenexperiment)

Si tiramos 6 veces la moneda, y sale 6 veces cara...



#### ¿diríamos que la moneda está cargada?

#### La "ciencia" hoy dice "sí".

#### Más precisamente:

"Hay evidencia significativa de que está cargada (p < 0.05, test binomial)"



Estadística (o inferencia, o análisis de datos) bayesiana como alternativa a la estadística frecuentista o "clásica"

Permite (entre otras cosas) incorporar nuestro conocimiento previo

Probabilidad como creencia

Podemos hacer afirmaciones sobre cuán probable es que la moneda esté cargada (prohibido en frecuentismo)



interpretación de la probabilidad

p(*lo que yo quiera*) p sólo para muestreo

Críticas al frecuentismo: 2 niveles

#### •críticas de fondo:

- ignora conocimiento previo
- dilema (mezcla) Fisher (significance testing) vs.
   Neyman/Pearson (hypothesis testing)
- -¿inconsistente? (discusión todavía abierta)

#### •críticas al (ab)uso:

- -p hacking
- -uso ciego en general
- no específico del frecuentismo





## Inferencia Bayesiana



Teorema de Bayes

prior:  $\theta \sim \text{Uniform}(0,1) = \text{Beta}(1,1)$   $\theta \sim \text{Beta}(100,100)$ posterior con Bayes:  $p(\theta|k) = \frac{p(k|\theta)p(\theta)}{p(k)}$ 

# Inferencia Bayesiana Modelo

ikelihood:  

$$p(k|\theta) = \binom{n}{k} \theta^k (1-\theta)^{n-k}$$

$$k \sim \text{Binomial}(\theta, n)$$

 $\left( \begin{array}{c} \theta \\ k \end{array} \right)$ 





# *posterior* (luego de 6 caras)

#### prior

 $\theta \sim \text{Uniform}(0, 1) = \text{Beta}(1, 1)$  $\theta \sim \text{Beta}(100, 100)$ 



### Acumulación de Evidencia



"The posterior is the new prior"

## Redes Bayesianas

p(B, E, A, P, R) = p(B)p(E|B)p(A|B, E)p(P|A, B, E)p(R|P, A, B, E)

![](_page_15_Figure_2.jpeg)

p(B, E, A, P, R) = p(B)p(E)p(A|B, E)p(P|A)p(R|E)

## Modelos Jerárquicos

![](_page_16_Figure_1.jpeg)

## Inferencia Bayesiana

- Incorpora conocimiento *a priori* en forma natural (¡y obligatoria!)
- Elude los *p values*
- Responde en términos de distribuciones de probabilidad (nuestro grado de creencia)
- Datos secuenciales: modelo de aprendizaje
- Redes, modelos jerárquicos, estructura x estadística

#### ¿Por qué ahora? Bayes/Laplace siglo XVIII Keynes 1920s de Finetti 1930, *Probabilismo*

![](_page_18_Picture_1.jpeg)

![](_page_18_Figure_2.jpeg)

![](_page_18_Picture_3.jpeg)

## computadoras + algoritmos uso práctico

inferencia bayesiana vs. estadística frecuentista

#### abordaje moderno: convivencia

- proyectos de largo plazo, con un especialista en el campo
  fuerte en modelado
- software bundles
  uso repetido
  - •modelado mínimo

•¿más 'honesta'?

Pero... ¿por qué probabilidades? ¿por qué Bayes?

Dutch book arguments -coherencia

Axiomas de Cox para los niveles de creencia:
1) Representados por un número real
2) "Sentido común" (inc. lógica Aristotélica)
3) Consistencia

Alternativamente:

estadística en términos de toma de decisiones, minimizar la péridida/maximizar la utilidad

Racionalidad en contextos de incertidumbre... ¡Modelo del pensamiento humano!

## Desde Aristóteles...

![](_page_21_Picture_1.jpeg)

Lógica

#### Todo hombre es mortal Sócrates es hombre Ergo Sócrates es mortal

Planteada como modelo del pensamiento

![](_page_21_Picture_5.jpeg)

#### La Paradoja de Linda

![](_page_22_Picture_1.jpeg)

Sesgos y Heurísticas, hombre irracional (Tversky & Kahneman, 1980s)

## Programa de la Cognición Bayesiana

- Lógica es adecuada en contextos de **certidumbre**
- Cuando hay incertidumbre, el lenguaje racional es la teoría de probabilidad
- Racionalidad acotada por nuestros recursos de cómputo: ilusión de irracionalidad
- Programa **general** y **cuantitativo**

## Inferencia Causal

0 s

![](_page_24_Figure_1.jpeg)

## Teoria de la Mente (joint Belief-Desire)

![](_page_25_Figure_1.jpeg)

![](_page_25_Figure_2.jpeg)

![](_page_25_Figure_3.jpeg)

## False Belief

Variable	Description	States
World $(W)$	Location of the toy.	0: Original location, 1: New location.
Access $(V)$	Could Sally see the toy moved?	0: No, 1: Yes.
Action $(A)$	Where Sally looks for her toy.	0: Original location, 1: New location.
Belief $(B)$	Where Sally thinks the toy is.	0: Original location, 1: New location.
Desire $(D)$	Sally's primary desire.	1: To find the toy, 0: Anything else.

![](_page_26_Figure_2.jpeg)

## Física Intuitiva

![](_page_27_Picture_1.jpeg)

![](_page_27_Figure_2.jpeg)

## Fundamentos de Inferencia Bayesiana La práctica

## Operacionales

- •Trabajo en grupos de N < 3 (N<=2)
- Modalidad "Hágalo Usted Mismo"
- •Mayormente en computadora
- •Seguimos apunte de Wagenmakers & Lee
- Herramienta a elección

# Herramientas: Programación Probabilística

INFER age, has\_heart\_disease FROM patients
WHERE age > 30 WITH CONFIDENCE 0.8 LIMIT 3;

age	has_heart_disease	age	has_heart_disease
66	???	66	yes
44	yes		yes
31	???	31	777

# Lenguajes Probabilísticos

#### Expresivos

Rápidos

- Figaro (Scala)
- WebPPL (Javascript, probmods.org)

- STAN
- WinBUGS, JAGS (R)
  - PyMC3 (Python)

Edward (TensorFlow, <u>edwardlib.org</u>)
 *Deep Probabilistic Programming*

Venture, BayesDB, Anglican...

# WinBUGS/jags

- Enlatado/open source
- Interfaz gráfica, pero se puede usar sin
- Sintaxis cercana a R
- •Scripts de MATLAB y R para correr
- •Usado en el apunte
- •Herramienta más estándar, no muy flexible
- http://mcmc-jags.sourceforge.net/

# WinBUGS/jags

```
# Difference Between Two Rates
1
23
   model {
4
5
   # Prior on Rates
  theta1 \sim dbeta(1,1)
6
   theta2 ~ dbeta(1,1)
7
8
9
   # Observed Counts
  k1 ~ dbin(theta1,n1)
10
   k2 ~ dbin(theta2,n2)
11
12
   # Difference between Rates
13
   delta <- theta1-theta2
15
16
   }
```

# Calling matjags.m

```
34 %% Defining observed data
35 k1=0; % number of observed successes
36 n1=10; % number of observations total
37
   k2=10;
  n2=10;
38
39 % Create a single structure that has the data for all observed JAGS nodes
  %datastruct = struct('k',k,'n',n);
40
   datastruct = struct('k1',k1, 'k2',k2, 'n1',n1, 'n2',n2);
41
42
43 %% Set initial values for latent variable in each chain
44
   for i=1:nchains
       S.theta1 = 0.5; % An Initial Value for the Success Rate
45
       S.theta2 = 0.5; % An Initial Value for the Success Rate
46
       initO(i) = S; % initO is a structure array that has the initial values for all latent v
47
   end
48
49
50 %% Calling JAGS to sample
   doparallel = 0; % do not use parallelization
51
52 fprintf( 'Running JAGS...\n' );
53
   tic
54
55
    [samples, stats, structArray] = matjags( ...
56
       datastruct, ...
                                      % Observed data %fullfile('Rate_1.txt'),
       fullfile(pwd, 'Rate_2.txt'), ... % File that contains model definition
57
                                       % Initial values for latent variables
58
       init0, ...
        'doparallel' , doparallel, ... % Parallelization flag
59
        'nchains', nchains,...
60
                               % Number of MCMC chains
        'nburnin', nburnin,...
                                      % Number of burnin steps
61
        'nsamples', nsamples, ... % Number of samples to extract
62
        'thin', 1, ...
                                         % Thinning parameter
63
        'dic', 1, ...
                                          % Do the DIC?
64
        Imanitarnarame! [Idaltal] elithetall
                                                      & list of latent variables to monit
65
```

s.p

# pymc

- •Librería de python
- •Más flexible, v2 menos robusta, v3?
- python
- https://pypi.python.org/pypi/pymc

```
2 import numpy as np
3
  import pymc
                                                                        pymc
4
5 def make_model(data, subject_trials):
6
7
       n_blocks=data.shape[1]
8
       n_trials_0=subject_trials/2
9
       n_trials_1=subject_trials/2
10
       theta0=np.empty(n_blocks, dtype=object)
11
       theta1=np.empty(n_blocks, dtype=object)
12
13
       k0=np.empty(n_blocks, dtype=object)
       k1=np.empty(n_blocks, dtype=object)
14
15
16 -
       for i in range(n_blocks):
           theta0[i]=pymc.Uniform('theta0_{0}'.format(i), 0, 1)
17
           theta1[i]=pymc.Uniform('theta1_{0}'.format(i), 0, 1)
18
19
           k0[i]=pymc.Binomial('k0_{0}'.format(i), p=theta0[i], n=n_trials_0, value=data[
20
           k1[i]=pymc.Binomial('k1_{0}'.format(i), p=theta1[i], n=n_trials_1, value=data[:
21
22
23
       @pymc.deterministic
24
       def delta(x=theta0, y=theta1):
25
           return [xi-yi for xi,yi in zip(x,y)]
26
27
       return locals()
28
29
30
31
   model=pymc.MCMC(testBernoulliModel)
32
   model.sample(iter=1000, burn=100, thin=5)
33
34
```

# WebPPL

- Lenguaje funcional probabilístico, subset de JavaScript
- Muestras <-> Ejecuciones
- Diseñado para ciencias cognitivas
- "Lenguaje de la mente"
- Tutorial Bayes: https://probmods.org
- Lenguaje en profundidad: http://dippl.org/

## WebPPL

```
var options = {method: 'enumerate'}
var model = function () {
  var A = flip()
  var B = flip()
  var C = flip()
  var D = A + B + C
  //add the desired assumption:
  condition(D \ge 2)
  return A
};
var dist = Infer(options, model)
viz(dist)
```

# Edward

#### Models

Most Edward random variables are light wrappers around distributions in TensorFlow. Therefore the list of available random variables depends on the TensorFlow version installed. For TensorFlow 1.1.0, the following are available:

![](_page_39_Figure_3.jpeg)

Running inference is as simple as running one method.

```
inference = ed.Inference({z: qz, beta: qbeta}, {x: x_train})
inference.run()
```

```
import tensorflow as tf
import edward as ed
from edward.models import Bernoulli, Beta, Binomial
import matplotlib.pyplot as plt
import seaborn as sns
##Single coin weight inference
##Model:
theta = Beta(1.0, 1.0)
x = Bernoulli(probs=theta)
##Sampling:
with tf.Session() as sess:
    for i in range(10):
        print(x.eval())
##Observations:
data=1
##Infer:
qtheta = Beta(tf.Variable(1.0), tf.Variable(1.0))
inference = ed.KLqp({theta: qtheta}, {x: data})
inference.run()
##Results:
qtheta_samples = qtheta.sample(1000).eval()
print(qtheta_samples.mean())
plt.hist(qtheta_samples)
plt.show()
```

# Edward