

Bayesískar aðferðir  
Málstofa Viðskipta- og hagfræðideildar HÍ.

Helgi Tómasson

10-03-2004

# Thomas Bayes

From Wikipedia, the free encyclopedia.

**Thomas Bayes** (c. 1702–April 7, 1761) was a [British mathematician](#) and [Presbyterian](#) minister, known for having formulated a special case of [Bayes' theorem](#). Bayes was elected Fellow of the [Royal Society](#) in 1742.

Born in [London, England](#), Bayes died in [Tunbridge Wells, Kent](#). He is interred in [Bunhill Fields Cemetery](#) in London, where many [Nonconformists](#) are buried.



## Table of contents

- [1 Works by Thomas Bayes](#)
- [2 Was Bayes a Bayesian?](#)
- [3 Bayesian inference and spam](#)
- [4 References](#)
- [5 External links](#)

## Works by Thomas Bayes

Bayes is known to have published two works in his lifetime: *Divine Benevolence, or an Attempt to Prove That the Principal End of the Divine Providence and Government is the Happiness of His Creatures* (1731), and *An Introduction to the Doctrine of Fluxions, and a Defence of the Mathematicians Against the Objections of the Author of the Analyst* (published anonymously in 1736), in which he defended the logical foundation of [Isaac Newton's calculus](#) against the criticism of [George Berkeley](#), author of *The Analyst*. It is speculated that Bayes was elected to the Royal Society on the strength of the *Introduction to the Doctrine of Fluxions*, as he is not known to have published any other mathematical works during his lifetime.

Bayes' solution to a problem of "inverse probability" was presented in the *Essay Towards Solving a Problem in the Doctrine of Chances* (1763), published posthumously by his friend [Richard Price](#) in the *Philosophical Transactions of the Royal Society of London*. This essay contains a statement of a special case of [Bayes' theorem](#).

In the first decades of the [eighteenth century](#), many problems concerning the probability of certain events, given specified conditions, were solved. For example, given a specified number of white and black balls in an urn, what is the probability of drawing a black ball? These are sometimes called "forward probability" problems. Attention soon turned to the converse of such a problem: given that one or more balls has been drawn, what can be said about the number of white and black balls in the urn? The *Essay* of Bayes contains his solution to a similar problem, posed by [Abraham de Moivre](#), author of *The Doctrine of*

## Yfirlit

- Markmið: Áróður fyrir hugmyndafræði og tækni
- Bakgrunnur: Ályktunarfræði í tölfraeði
- Bayes mat í einföldu líkani
- Tæknileg vandamál
- Einfalt tölvudæmi, BUGS og CODA forritin
- Lokaorð

## Bakgrunnur

- Regla Bayes:

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)}$$

- Líkindfræði er stærðfræði, með skilgreiningum, setningum sönnunum, sýnidæmum. Atburður, líkur, hending(random-variable), dreifing, Ýmsar dreifingar þykja tengjast raunverulegum fyrirbærum og verið heiðraðar með sérstöku nafni, normal, poisson, Bernoulli ,gamma, beta, o.s.frv.
- Hagnýtingar á líkindafræði: Ályktunarfræði (Inference) og ákvörðunarfræði (decision theory).
- Tölfræði = Ályktunarfræði (Inference) + Líkindafræði
- Ýmsir metríu-kultúrar = Econometrics, biometrics, psychometrics, sociometrics, chemometrics, technometrics, criminometrics o.s.frv.
- Ályktanir út frá mælingum krefjast þess að líkur séu túlkaðar, þ.e. hvað þýðir  $P(A) = 1/2$ ?
- Túlkun 1, tíðniskóli (frequentistic): Mælikvarði á tíðni atburða.
- Túlkun 2, Bayes-skóli: Mælikvarði á vissu.

- Athugið ályktun út frá mælingum er alltaf í tengslum við líkan:

$$\mathbf{x}|\boldsymbol{\theta} \sim \pi(\mathbf{x}|\boldsymbol{\theta})$$

þar sem

$\mathbf{x} = (x_1, x_2, \dots, x_n)'$  er vektor af mælingum

$\pi(\mathbf{x}|\boldsymbol{\theta})$  er líkindadreifing, sem stýrt er af stikanum  $\boldsymbol{\theta}$

Til dæmis getum verið að tala um slembiúrtak (random sample) úr normaldreifingu þar sem

$\pi(\mathbf{x}|\boldsymbol{\theta})$  er  $N(\boldsymbol{\mu}, \Sigma)$

$\boldsymbol{\theta} = (\mu, \sigma^2)$  og  $\boldsymbol{\mu} = (\mu, \dots, \mu)$  og

$$\Sigma = \sigma^2 \begin{bmatrix} 1 & 0 & \cdots & 0 \\ 0 & 1 & \cdots & 0 \\ 0 & 0 & \ddots & 0 \\ 0 & \cdots & \cdots & 1 \end{bmatrix}$$

- Frequentistar líta á  $\boldsymbol{\theta}$  sem fasta stærð, í praxís óbekkta, sem ekki hafi neina líkindadreifingu, því endurtekning á tilrauninni myndi ekki breyta  $\boldsymbol{\theta}$ .
- Bayesíanar líta óbekktan stika,  $\boldsymbol{\theta}$  sem hendingu og óvissuna um þann stika skuli setja fram í formi líkindadreifingar.
- Frequentisti setur fram líkan

$\mathbf{X}|\boldsymbol{\theta}$  safnar gögnum  $\mathbf{x}$  og fær mat ML,MM,OLS ..

$$\hat{\boldsymbol{\theta}}$$

- Síðan ályktar hann um  $\boldsymbol{\theta}$  út frá  $\hat{\boldsymbol{\theta}}$ , tjáir sig um nákvæmni með ör-yggismörkum (confidence interval) og prófar kenningar um  $\boldsymbol{\theta}$  með LR (likelihood-ratio), Wald eða LM (Lagrange-multiplier, score ) prófum.
- Vandi að túnka p-gildi fyrir frequentista. Neyman og Pearson deildu við Fischer um þau atriði milli 1930 og 1940. Sjá t.d. Spanos og Berger.  $H_0$  hafnað vegna þess að ef  $H_0$  er rétt þá þykir mér mæld útkoma of ótrúleg.
- Bayesíana vinna allt öðruvísi. Áður en gögnum er safnað er sett fram skoðun á stikanum  $\boldsymbol{\theta}$ . Þessi skoðun er sett fram í formi líkindadreifingar,

$\pi(\boldsymbol{\theta})$  a priori dreifningin

$$\text{líkanið er } \mathbf{X}|\boldsymbol{\theta} \sim \pi(\mathbf{x}|\boldsymbol{\theta})$$

gögnum  $\mathbf{x}$  safnað

og reiknuð út a posteriori dreifningin með reglu Bayes

$$\pi(\boldsymbol{\theta}|\mathbf{x}) = \frac{\pi(\boldsymbol{\theta})\pi(\mathbf{x}|\boldsymbol{\theta})}{\int \pi(\boldsymbol{\theta})\pi(\mathbf{x}|\boldsymbol{\theta})d\boldsymbol{\theta}}$$

- Síðan má skilgreina bayes mat út frá posteriori dreifingunni, t.d:

$$\hat{\boldsymbol{\theta}}_{BAYES} = E_{\pi(\boldsymbol{\theta}|\mathbf{x})}(\boldsymbol{\theta})$$

eða reikna miðtölù, mode eða eitthvað annað út frá posteriori dreifingunni.

- Athugið að nákvæmnina meta Bayesianar með „highest-probability” region fyrir  $\boldsymbol{\theta}$  og ályktað eru um kenningar með því að reikna „posterior odds”. Þ.e. líkur eru notaðar beint í ályktuninni.
- Upplagt er að koma sinni hlutdrægni á framfæri með vali á priori dreifingu.
- Hvað á að gera ef lítið er vitað um  $\boldsymbol{\theta}$ ? Hvernig á setja slíkt fram á formi líkindadreifngar?
- Í praxís vel flatan prior. Hugtakið „non-informative-prior” hefur vald- ið Bayesiönum heilabrotum. Ýmsar lausnir, lagðar til svo sem Jeffrey's prior, minimal-Shannon-information. Shannon-information er skilgreint:

$$I_\pi = \int \pi(\boldsymbol{\theta}) \log(\pi(\boldsymbol{\theta})) d\boldsymbol{\theta}$$

Finn það fall  $\pi$  þannig að upplýsingaauki úr tilraun séu sem mestur.

$$I_x = \int \pi(\boldsymbol{\theta}|\mathbf{x}) \log(\pi(\boldsymbol{\theta}|\mathbf{x})) d\boldsymbol{\theta}$$

hámarka

$$I_x - I_\pi$$

- Get valið flatan improper-prior, Bayesianar ekki sammála hér.  
Ath. Ef  $\pi(\log(\sigma))$  er flatt þá er  $\pi(\sigma)$  ekki flatt.
- Í praxís vel eitthvað sem er nálægt því að vera flatt fyrir áhugverð gildi á  $\boldsymbol{\theta}$ .

- Bayesískar aðferðir geta haft góða frequentistic eiginleika, t.d. lítinn mean-square-error. Maximum-likelihood aðferðir er **asymptotísk optimal** en geta haft leiðinlega eiginleika í litlum úrtökum.
- James-Stein og ridge-regression eru aðferðir, sem auka stöðugleika í mati, hafa verið leiddar út með empirical Bayes aðferðum. Empirical Bayes aðferðir ganga út á að nota Bayes formúlur en stinga inn gildum á parametrum úr prior dreifingunni sem er metin út frá mælingunum.

## Hagnýting og tæknileg vandamál

- Áður voru Bayes aðferðir fyrst og fremst heimsspekilegar (og stærðfræðilegar).
- Á síðustu árum hefur þetta breyst og nú er Bayes aðferðafræði orðinn praktískur möguleiki í hagnýtum rannsóknum.
- Tæknilega hefur verið nánast ómögulegt að reikna út integralið í posteriori dreifingunni.
- Það er hægt ef líkanið og priori-dreifingin mynda „conjugate”-par. Þá verða priori dreifingin og posteriori dreifingin bæði úr sömu fjölskyldu. Þ.e. prior-líkan parið er „closed under sampling”
- Dæmi: Vil álykta um meðaltal í normaldreifingu,  $N(\mu, \sigma^2)$ . Gerum ráð fyrir að  $\sigma$  sé þekkt þá er skref 1 að setja fram prior

$$\pi(\mu) \sim N(a, \tau) \text{ fæ mælingu } x \text{ úr}$$

$N(\mu, \sigma)$  nú má sýna með algebru og reglu Bayes að

$$\pi(\mu|x) \sim N\left(x \frac{\tau}{\sigma^2 + \tau} + a \frac{\sigma^2}{\sigma^2 + \tau}, \frac{1}{1/\sigma^2 + 1/\tau}\right)$$

þ.e. a posteriori dreifing varð ný normaldreifing. Ef  $\sigma$  hefði verið óþekkt hefið mátt nota normal-gamma prior og fá að a posteriori dreifingin er t-dreifing.

- Það hægt að leiða út conjugate prior fyrir exponential family dreifingar. Og þá er hugsanlegt að vinna analýtisk með posteriori dreifinguna. Fyrir aðra a priori dreifingar er þetta yfirleitt erfitt.
- Því verður að grípa til númerískra aðgerða. Það er erfitt að integrera númerískt í mörgum víddum. Til deterministískar reglur, Gaussian quadrature sem ganga í lágum víddum (1,2,3).
- Nútímapraxís byggir á hermunum (simulations). P.e. til að meta integralið

$$\int g(\boldsymbol{\theta}) d\boldsymbol{\theta} \text{ er safnað gildum á } \boldsymbol{\theta}$$

með random generator og reiknað

$$\frac{1}{S} \sum_{i=1}^S g(\boldsymbol{\theta}_i)$$

- Random sample ekki skynsamlegt. Menn hafa reynt a) importance sampling (svipað og stratified sampling) og Markov-Chain-Monte-Carlo (MCMC) aðferðir. Þekkt prinsíp í MCMC eru Metropolis-Hastings aðferðin og Gibbs sampler.
- Tæknilegur vandi er að búa til random tölur úr a posteriori-dreifingunni. Ef ákveðnum stærðfræðilegum skilyrðum er fullnægt er hægt er að hanna Markov-keðju sem hefur jafnvægisdreifingu sem er sama og posteriori dreifingin.

- Hugmyndin er því sú að setja af stað keðju, eftir ákveðin tíma eru gildi í keðjunni „representatív” fyrir posteriori dreifinguna. Þá er safnað úr keðjunni gögnum þannig að góð hugmynd fæst um dreifinguna.
- Vandi er að vita hvenær er maður kominn nógu langt? Þ.e. hvað þarf burn-in tímabilið að vera langt? Mikilvægt að velja startgildi rétt.
- Próaðar hafa verið convergence-diagnostic aðferðir.
- Sýni lítið dæmi með notkun á BUGS (Bayesians-Using-Gibbs-Sampler) og CODA (Convergence-Output-Diagnostic-Analysis).

## Einfalt dæmi

Einföld aðhvarfsgreining(regression)

x y

1 1

2 3

3 3

4 3

5 5

Líkanið er

$$Y_i = \alpha + \beta X_i + \varepsilon_i \quad \varepsilon \sim N(0, \sigma^2)$$

$$\text{a priori dreifingar } \alpha \sim N(0, 10000) \quad \beta \sim N(0, 10000)$$

$$\sigma^{-2} \sim \text{gamma}(0.00001, 0.00001)$$

Venulegt niðurstæða úr vengulegu tölfraðiforriti er t.d.  $\hat{\sigma} = 0.73$

	Estimate	Std. Error	t value	Pr(> t )
(Intercept)	0.6000	0.7659	0.78	0.4906
x	0.8000	0.2309	3.46	0.0405

## CODA-ouput

1. Empirical mean and standard deviation for each variable, plus standard error of the mean:


	Mean	SD	Naive SE	Time-series SE
alpha	0.6719	1.2109	0.017124	0.030980
beta	0.7768	0.3605	0.005099	0.009386
sigma	0.9993	0.6285	0.008889	0.013761
tau	1.8749	1.5220	0.021524	0.028852

2. Quantiles for each variable:

	2.5%	25%	50%	75%	97.5%
alpha	-1.672447	0.03057	0.6327	1.225	3.263
beta	.001338	60776	0.7870	0.968	1.468
sigma	0.415499	0.62246	0.8200	1.171	2.649
tau	0.142518	0.72870	1.4874	2.581	5.792

CODA diagnostics options menu


- 1:Display current diagnostic options
- 2:Window sizes for Geweke's diagnostic
- 3:Bin size for plotting Geweke's diagnostic
- 4:Bin size for plotting Gelman & Rubin's diagnostic
- 5:Parameters for Raftery & Lewis' diagnostic
- 6:Halfwidth precision for Heidelberger & Welch's diagnostic
- 7:Combine chains to calculate correlation matrix



Mynd 1: Útkoma úr CODA




## HIP Software and Physics project



The 24 nodes of the Celeron ATX blade server [1].

23.10.2003



Here the power supply tower can be seen.

Tomas Lindén

Mynd 2: Linux-cluster í smíðum

### 1... GENERALISED LINEAR MODELS

#### 1.3. GENERAL PRINCIPLES OF MODELLING

- IT IS ART
- ALL MODELS ARE WRONG
- SOME OF THEM ARE MORE USEFUL THAN OTHERS
- WE SEEK FOR MODELS WHICH DESCRIBE REALITY
- WE FIT AND CHECK MANY DIFFERENT MODELS
- ALWAYS USE SOME DIAGNOSTICS FOR CHECKING THE GOODNESS OF FIT

### 2... CLASSIC BUGS

- 2.1. INTRODUCTION: WHAT IS BUGS?
- 2.2. A SIMPLE EXAMPLE
- 2.3. EXAMPLE 2: BINOMIAL DATA
- 2.4. EXAMPLE 3: BERNOULLI DATA
- 2.5 EXAMPLE 4: MODELS FOR 2X2 CONTINGENCY TABLES
- 2.6 EXAMPLE 5: MODEL FOR 3-WAY TABLES

### 2... CLASSIC BUGS

#### 2.1. INTRODUCTION: What is BUGS

- BUGS: Bayesian inference Using Gibbs Sampling
- Computing Language for definition of the Model (likelihood, prior)
- Computes the full Conditional Distributions and generates samples from log-concave posterior distributions

### 2... CLASSIC BUGS

#### 2.1. INTRODUCTION: What is BUGS

- The project started at (about) 1995
- 1998: 1st version of Windows (Winbugs)
- MRC Biostatistics Unit in Cambridge (Spiegelhalter, Gilks, Best, Thomas)
- Now: developed jointly with the Imperial College
- Free from:  
<http://www.mrc-bsu.cam.ac.uk/bugs/>

### 2... CLASSIC BUGS

#### 2.1. INTRODUCTION: What is BUGS

##### BEWARE:

**GIBBS SAMPLING CAN BE DANGEROUS**

### 2... CLASSIC BUGS

#### 2.1. INTRODUCTION: What is BUGS

##### Why?

- Wrong Results due to lack of convergence
- Slow convergence
- Bad Starting Values
- Bad Construction of Model
- Over-parameterised Model

Words: B. Carlin

Music: Neil Diamond/The Monkees/Smashmouth (“I’m a Believer”)

**Intro:** (key/guitar lick)

**V1:** I thought inference was just a fairy tale,

Confused by stats and probability,

Frequentist approaches (doo-doot doo-doot)

made no sense to me (doo-doot doo-doot)

Summarizing evidence by  $p$ ?

**Chorus:** Then I saw Tom Bayes – Now I’m a believer,

Without a trace – of doubt in my mind,

[I’m a] Bayesian (ooooh) – Oh, I’m a believer –

I couldn’t  $p$  now if I tried!

**V2:** I thought likelihood was just the only thing,  
Turn the crank and get the MLE,  
What's the use of thinking (doo-doot doo-doot)  
Disconnect your brain (doo-doot doo-doot)  
Play along and minimize the pain...

**Chorus:** (repeat)

**Solo:** (keys/guitar)

**V3:** SAS was out to get me (doo-doot doo-doot)  
(partial) – that's the way it seemed (doo-doot doo-doot)

Fixed effects and forced normality...

**Chorus:** (repeat 2x w/assorted hollering and out!)

## Lokaorð

- Bayes hugmyndafræði er frábrugðin tíðintúlkun.
- Oft er hægt að taka tíðnitúlkunarniðurstöður og sjá hvers konar prior sá rannsakandi hefði haft ef hann hefði verið Bayesian.
- Tölvutækni, MCMC aðferðir gera Bayésísk vinna að praktískum möguleika.
- Með MCMC tækninni er hugsanlega hægt að meta flókin líkön,
- Fræðin um óvissu eru „exact” vísindi.