

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-kúltúrar = Econometrics, biometrics, pschychometrics, 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.

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*

- 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

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

- Frequentistar líta á $\boldsymbol{\theta}$ sem fasta stærð, í praxís óþekkta, sem ekki hafi neina líkindadreifningu, því endurtekning á tilrauninni myndi ekki breyta $\boldsymbol{\theta}$.
- Bayesíanar líta óþekktan 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 θ út frá $\hat{\theta}$, tjáir sig um nákvæmni með öryggismörkum (confidence interval) og prófar kenningar um θ með LR (likelihood-ratio), Wald eða LM (Lagrange-multiplier, score) prófum.
- Vandi að túlka 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.
- Bayesíanar vinna allt öðruvísi. Áður en gögnum er safnað er sett fram skoðun á stikanum θ . Þessi skoðun er sett fram í formi líkindadreifingar,

$\pi(\theta)$ a priori dreifningin

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

gögnum \mathbf{x} safnað

og reiknuð út a posteriori dreifningin með reglu Bayes

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

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

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

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

- Athugið að nákvæmnina meta Bayesianar með „highest-probability” region fyrir θ 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 θ ? Hvernig á setja slíkt fram á formi líkindadreifingar?
- Í praxís vel flatan prior. Hugtakið „non-informative-prior” hefur valdið Bayesiönnum heilabrotum. Ýmsar lausnir, lagðar til svo sem Jeffrey’s prior, minimal-Shannon-information. Shannon-information er skilgreint:

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

Finn það fall π þannig að upplýsingaauki úr tilraun séu sem mestur.

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

hámarka

$$I_{\mathbf{x}} - I_{\pi}$$

- 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 θ .

- 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 σ 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 σ hefði verið óþekkt hefði 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 analýtísk 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 determinstískar reglur, Gaussian quadrature sem ganga í lágum víddum (1,2,3).
- Nútímapraxís byggir á hermunum (simulations). Þ.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.
- Vandí er að vita hvenær er maður kominn nógu langt? Þ.e. hvað þarf burn-in tímabilið að vera langt? Mikilvægt að velja startgildi rétt.
- Þróaðar 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 niðurstaða úr vengulegu tölfræðiforriti 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

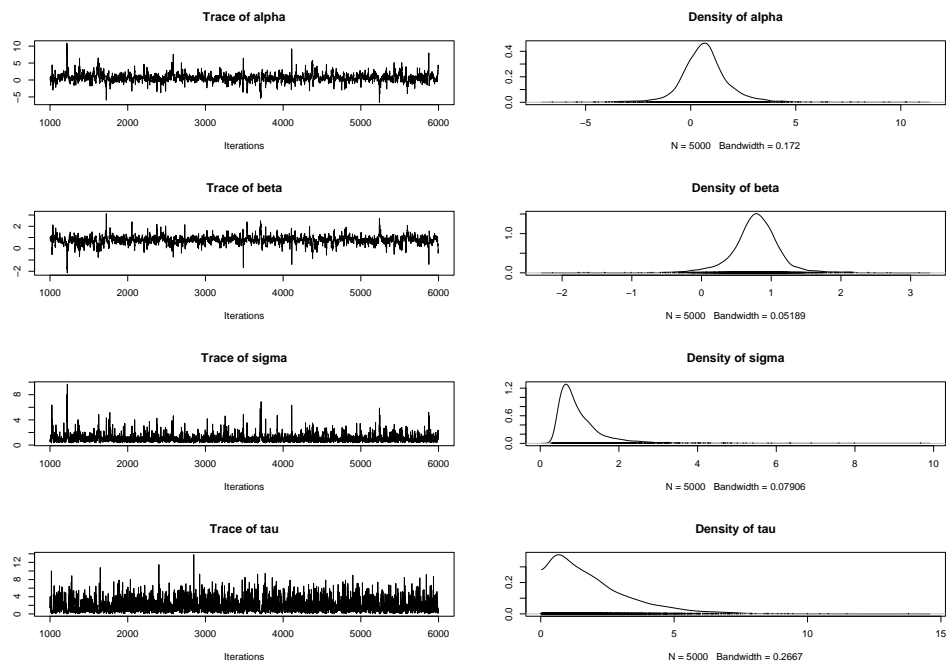
3:Bin size for plotting Geweke's diagnostic

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



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

23.10.2003

8



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 Bayesíska vinnu að praktískum möguleika.
- Með MCMC tækninni er hugsanlega hægt að meta flókin líkön,
- Fræðin um óvissu eru „exact” vísindi.