

Modelos Dinâmicos Bayesianos

Helio S. Migon Mariane B. Alves

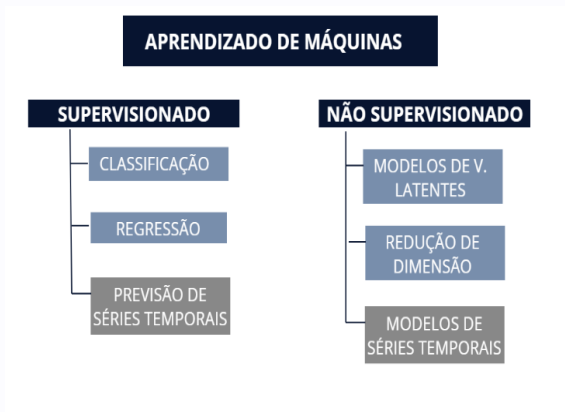
Instituto de Matemática
Universidade Federal do Rio de Janeiro

2018

Aprendizado de Máquina


Aprendizado de Máquina

- Métodos e teorias para extrair informação em **grandes conjuntos de dados**.



Estilos de Aprendizado de Máquina (AM)

- Supervisionado - foco em previsões **acuradas**.
- Não Supervisionado - descrição compacta de um **bolo de dados**.



Aprendizado Supervisionado

- Dados - $\mathcal{D} = \{(x_n, y_n), n = 1, \dots, N\}$
- Objetivo: aprender relação entre x (input) e y (output).



- Predição: Para um novo input $x_f \notin \mathcal{D}$, com mesmo processo gerador de dados, desejo:

$$p(y_f|x_f, \mathcal{D}) = \int p(y|x_f, \theta)p(\theta|\mathcal{D})d\theta$$

- Função de perda: (utilidade) para aferir acurácia em predições pontuais.
- Exemplos:
 - 1 Classificação: y discreto - classes
 - 2 Regressão - y contínuo

- Objetivo: descrição compacta dos dados em \mathcal{D}
- Dados - $\mathcal{D} = \{x_n, n = 1, \dots, N\}$
- Modelo: $p(x) = \int p(x|\theta)p(\theta|\mathcal{D})$
- Exemplos: Exemplos:
 - 1 Conglomeração
 - 2 Redução de dimensionalidade

Introdução

Série temporal - conjunto de observações ordenadas (no tempo).

- ▶ Tempo pode ser espaço, profundidade, ...;
- ▶ Observações vizinhas são dependentes;



Estudo de séries temporais:

modelagem ↘
análise ↗

dessa dependência.

- ▶ Técnicas específicas a séries temporais

Exemplos de aplicações

✓ Economia

- preços diários de ações
- taxa de desemprego mensal

✓ Medicina

- níveis de eletrocardiograma
- níveis de eletroencefalograma

✓ Epidemiologia

- casos semanais de sarampo
- mensais de AIDS

✓ Meteorologia

- temperatura diária
- registro de marés

✓ etc.

Série temporal é conjunto de observações $\{Y(t), t \in T\}$

Y - variável de interesse

T - conjunto de índices

Tipos de séries temporais

1. Discreta : $T = \{t_1, t_2, \dots, t_n\}$

Ex : Exportações mensais de 1970 a 1990

$T = \{01/1970, 02/1970, \dots, 11/1990, 12/1990\}$

Notação : Y_t

Tipos de séries temporais

1. Discreta : $T = \{t_1, t_2, \dots, t_n\}$

Ex : Exportações mensais de 1970 a 1990

$T = \{01/1970, 02/1970, \dots, 11/1990, 12/1990\}$

Notação : Y_t

2. Contínua : $T = \{t : t_1 < t < t_2\}$

Ex : Registro da maré no Rio durante 1 dia

$T = [0, 24]$ se unidade de tempo é a hora

Notação : $Y(t)$

Tipos de séries temporais

1. Discreta : $T = \{t_1, t_2, \dots, t_n\}$

Ex : Exportações mensais de 1970 a 1990

$T = \{01/1970, 02/1970, \dots, 11/1990, 12/1990\}$

Notação : Y_t

2. Contínua : $T = \{t : t_1 < t < t_2\}$

Ex : Registro da maré no Rio durante 1 dia

$T = [0, 24]$ se unidade de tempo é a hora

Notação : $Y(t)$

3. Multivariada : Observações são $\{Y_1(t), \dots, Y_k(t), t \in T\}$

Ex : Vendas semanais (Y_{1t}) e gastos com propaganda (Y_{2t}).

Tipos de séries temporais


Y também pode ser discreto ou contínuo.

Muitas vezes, Y é discreto mas pode ser tratado como contínuo.

Ex : Número de casos notificados de AIDS.

Podemos identificar T com $\{1, 2, \dots, n\}$

Exemplo de série temporal: Air Passengers



Objetivos de uma análise de séries temporais

Os principais objetivos são :

- (i) compreender o mecanismo gerador da série;
- (ii) prever o comportamento futuro da série.

Objetivos de uma análise de séries temporais

Os principais objetivos são :

- (i) compreender o mecanismo gerador da série;
- (ii) prever o comportamento futuro da série.

Compreender o mecanismo da série possibilita :

- descrever eficientemente o comportamento da série;
- encontrar periodicidades na série;
- descobrir razões para o comportamento da série (possivelmente através de variáveis auxiliares);
- controlar a trajetória da série.

Objetivos de uma análise de séries temporais

Os principais objetivos são :

- (i) compreender o mecanismo gerador da série;
- (ii) prever o comportamento futuro da série.

Compreender o mecanismo da série possibilita :

- descrever eficientemente o comportamento da série;
- encontrar periodicidades na série;
- descobrir razões para o comportamento da série (possivelmente através de variáveis auxiliares);
- controlar a trajetória da série.

Predizer o futuro possibilita :

- fazer planos a longo, médio e curto prazo;
- tomar decisões apropriadas.

Objetivos de uma análise de séries temporais

Objetivos (i) e (ii) estão interligados.

Só é possível prever bem rotineiramente se o modelo é adequado e vice-versa.

A não ser nos raros casos de modelos determinísticos, futuro envolve incerteza \rightarrow previsões não são perfeitas.

Objetivo é reduzir ao máximo os **erros de previsão**.

Central à análise de séries temporais está a construção de um modelo.

Modelo

Esquema de descrição (e explicação) que organiza informação (e experiências) de forma a propiciar aprendizagem e previsão.

Central à análise de séries temporais está a construção de um modelo.

Modelo

Esquema de descrição (e explicação) que organiza informação (e experiências) de forma a propiciar aprendizagem e previsão.

- Bom **modelo** permite **aprendizado** levando a **previsões** adequadas.
- Devido à incerteza presente, modelo é probabilístico.
- Deve também ser econômico (parsimônia).
- Descrição deve ser relativamente simples e flexível para poder se adaptar ao futuro (incerto) e facilitar aprendizado.

Modelagem, aprendizado e previsão

Aprendizado

É processamento de informação através do modelo.

Modelagem, aprendizado e previsão

Aprendizado

É processamento de informação através do modelo.

Previsão

É hipótese, conjectura ou especulação sobre o futuro.

Modelagem, aprendizado e previsão

Aprendizado

É processamento de informação através do modelo.

Previsão

É hipótese, conjectura ou especulação sobre o futuro.

- A natureza dinâmica de séries temporais faz com que modelos tenham que ter adaptabilidade no tempo.
- Tem que ser parametrizado de forma a permitir mudanças locais em sua estrutura.
- Veremos que essa mudança pode ser modelada estocásticamente, isto é, usando probabilidade.

Quando isso é feito dentro do contexto Bayesiano, temos uma série de vantagens como intervenção, função de transferência, estimação retrospectiva (alisamento) sendo obtidas naturalmente.

A idéia básica é definir modelos que representem a estrutura da série (componente cíclica, de tendência, ...).

Daí o nome de modelos estruturais. Quando método de inferência é Bayesiano → [modelos dinâmicos](#).

Característica básica : parâmetros que caracterizam o modelo mudam com o tempo probabilisticamente.

Ex: Queremos prever Y que sabemos ser influenciada por X .

Relação mais simples: $Y = X\theta + \epsilon$

Talvez melhor assumir θ mudando com o tempo

Modelagem, aprendizado e previsão

Regra de aprendizagem - Teorema de Bayes

- Modelos possíveis M_1, M_2, \dots, M_p com probabilidades $P(M)$, $M = M_1, M_2, \dots, M_p$;
- Observa-se Y cuja descrição é $P(Y | M)$; Verossimilhança do modelo M ;
- Após observar $Y = y$ temos $P(M | Y = y)$, $M = M_1, \dots, M_p$ dado por

$$\begin{aligned}P(M | Y = y) &= \frac{P(Y = y, M)}{P(Y = y)} \\&= \frac{P(Y = y | M) \times P(M)}{P(Y = y)} \\&\propto P(Y = y | M) \times P(M)\end{aligned}$$

$$\text{Posteriori} \propto \text{Verossimilhança} \times \text{Priori}$$

Básicos : previsão e estimação.

1. INTERVENÇÃO (ANTECIPATÓRIA)

Analista pode modificar modelo de acordo com informação prévia durante processo de observação.

Ex. : tabelamento dos juros

Básicos : previsão e estimação.

2. MONITORAÇÃO

Performance do modelo cai



Monitoração sinaliza



Mudanças são feitas

- Intervenção retrospectiva

Básicos : previsão e estimação.

3. RETROSPECÇÃO

Previsão : ver o que passado diz sobre futuro.

Também pode-se ver o que futuro diz sobre passado.

Importância secundária : controle.

Exemplo de *preditor ótimo*

Você recebe uma correspondência de uma firma que se diz especialista em previsões financeiras.

Como prova de sua capacidade preditiva ela encaminha junto a esta divulgação sua previsão para o estado do mercado na próxima semana: **Alta, Baixa.**

Na semana seguinte você verifica que ela acertou !!! Logo a seguir voce recebe nova carta com a previsão da semana seguinte.

Novamente ela acerta e isto se repete por 7 semanas consecutivas.

A firma é de fato uma previsora excepcional?

- Conjunto de Informação

$$D_t = \{y_1, \dots, y_t, I_t\}, \text{ onde}$$

I_t representa outras informações disponíveis.

y_1, \dots, y_t condicionalmente independentes dado θ

- Desejamos

$$p(y_{t+1}, \dots, y_{t+H} | D_t)$$

Exemplo:

$$p(y_{t+1}, y_{t+2} | D_t)$$

ou

$$p(y_{t+1} + y_{t+2} | D_t)$$

Suponha que

$$\begin{pmatrix} y_{t+1} \\ y_{t+2} \end{pmatrix} \sim \left[\begin{pmatrix} f_{t+1} \\ f_{t+2} \end{pmatrix}, \begin{pmatrix} Q_1 & Q_{12} \\ Q_{21} & Q_2 \end{pmatrix} \right]$$

Logo

$$E[y_{t+1} + y_{t+2}] = f_{t+1} + f_{t+2}$$

$$Var[y_{t+1} + y_{t+2}] = Q_1 + Q_2 + 2 \times Q_{12}$$

a) - Indústria de Bebida

Desejava-se prever a demanda por cidra na Inglaterra no final da década dos 70.

Apresentamos a seguir uma seqüência de gráficos exibindo o dado original, os erros de previsão associados a um modelo de crescimento linear, etc. . .

Exemplo da Cidra

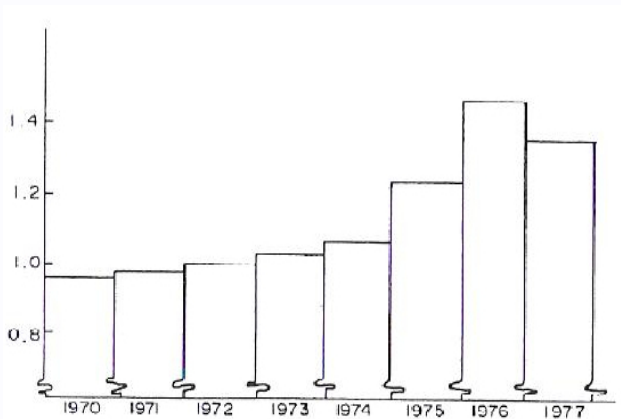


FIG. 1. Total issues (in scaled units).

Dados

Exemplo da Cidra

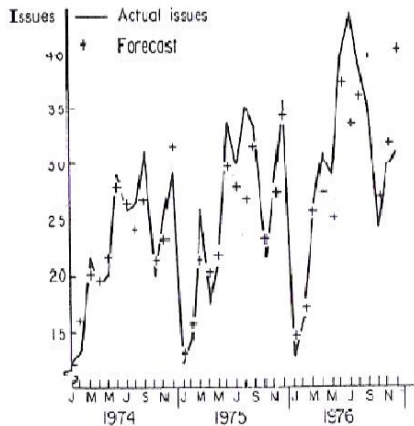


FIG. 2. Actual issues 1974–1975 and one-step ahead forecast from linear growth season

Erro de Previsão - Modelo Crescimento - Ano 1976

Exemplo da Cidra





FIG. 4. Actual issues 1977-78 and forecasts made in December 1976 for next 18 months (LGS mo)

Erro de Previsão - Modelo Crescimento - Anos 1977-78

Exemplo da Cidra



Actual issues 1977-78 and forecast made in December 1976 for next 18 months (complete model)

Erro de Previsão - Modelo Completo - Anos 1977-78

Exemplos

b) - Número de telefones nos EEUU.

Neste exemplo uma curva de crescimento amortecida




Figure 3. Number of residential telephones per household. x x x data, — forecasts, — — — two s.d. limits

Dados

Exemplos

b) - Número de telefones nos EEUU.

Neste exemplo uma curva de crescimento amortecida




Figure 4. Forecast residuals (—) with two s.d. limits (---)

Erros de Previsão

c) - Modelo Econométrico - micro fundamento

Este modelo foi desenvolvido para prever o *valor das exportações de produtos industrializados*, usando dados de Jun./79 até Dec./84. Período de grande crise mundial e várias desvalorizações do cruzeiro.

O modelo foi elaborado passo a passo com base nos conceitos elementares de oferta e demanda.

Oferta

Quantidade de bens exportados. É função de:

- | | |
|-------------------------------|---|
| i) preço em US\$ (p) | ii) taxa de câmbio "real" (r) |
| iii) hiato do produto (h) | iv) índice de preço americano (π) |

->

c) - Modelo Econométrico - micro fundamento

Este modelo foi desenvolvido para prever o *valor das exportações de produtos industrializados*, usando dados de Jun./79 até Dec./84. Período de grande crise mundial e várias desvalorizações do cruzeiro.

O modelo foi elaborado passo a passo com base nos conceitos elementares de oferta e demanda.

Demanda

Quantidade de bens brasileiros a ser importada. É função de:

- i) preço de exportação (p)
- ii) renda mundial (z)

->

Distribuições de Probabilidade

Variáveis Aleatórias

- *Variável ou Quantidade Aleatória* é aquela cujo valor nos é incerto.
Ex.:
 - X : Número resultando do lançamento de um dado
 - Y : Nível de glicose no sangue de um indivíduo.
- Sua incerteza é representada probabilisticamente, ex., $Pr(X = x) = \frac{1}{6}, x = 1, 2, 3, 4, 5, 6$.
- As Variáveis Aleatórias admitem várias classificações possíveis:
 - *Discreta* ou *Contínua*
 - *Observável* ou *Não Observável*

Exemplos:

- Discreta e observável: X
- Discreta e não observável: Indicador de doença num indivíduo
- Contínua e observável: Vendas de um produto em larga escala
- Contínua e não observável: Y

Variáveis Discretas são representadas pela **função de probabilidade**

$f(x) = Pr(X = x)$, que caracteriza completamente a incerteza a respeito de X pois

$$Pr(X \in A) = \sum_{x \in A} Pr(X = x) = \sum_{x \in A} f(x)$$

Variáveis Contínuas são representadas pela função de densidade de probabilidade ou **densidade** $f(x)$, que caracteriza a incerteza a respeito de X pois

$$Pr(X \in A) = \int_A f(x) dx$$

Exemplo: $\{f(x) = 1/[\pi(1 + x^2)]\}$ daqui, $\{Pr(X \in [-1, 2]) = 0,6\}$

Operações com funções de densidade de probabilidade

Sejam x , y , z variáveis aleatórias e seja $f(x, y, z)$ a função densidade de probabilidade conjunta dessas três variáveis aleatórias. Valem as seguintes identidades :

$$\begin{aligned}f(x|y) &= \frac{f(x, y)}{f(y)} \\f(x) &= \int_y f(x, y) dy \\f(x, y | z) &= \frac{f(x, y, z)}{f(z)}\end{aligned}$$

Resultados continuam válidos para x , y , e z vetores.

Operações com funções de densidade de probabilidade

Sejam x , y , z variáveis aleatórias e seja $f(x, y, z)$ a função densidade de probabilidade conjunta dessas três variáveis aleatórias. Valem as seguintes identidades :

$$\begin{aligned}f(x, y) &= \int_z f(x, y, z) dz \\f(x | y) &= \int_z f(x, z | y) dz \\f(x | y, z) &= \frac{f(y | x, z) f(x | z)}{f(y | z)}\end{aligned}$$

Resultados continuam válidos para x , y , e z vetores.

Distribuição Normal Univariada

A variável aleatória (v.a.) x tem **distribuição normal univariada** com média μ e variância σ^2 , denotada por $N(\mu, \sigma^2)$, se sua densidade é dada por:

$$f(x; \mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp \left\{ -\frac{1}{2\sigma^2} (x - \mu)^2 \right\} \quad , \quad x \in R$$

A distribuição normal padronizada é obtida quando $\mu = 0$ e $\sigma^2 = 1$.

$E(x) = \mu$ e $V(x) = \sigma^2$.

Distribuição Normal Multivariada

$X = (X_1, X_2, \dots, X_p)'$ tem **distribuição normal multivariada** (ou p -variada) com média μ e variância Σ , denotada por $N(\mu, \Sigma)$, se sua densidade é dada por :



$$f_N(x; \mu, \Sigma) = (2\pi)^{p/2} |\Sigma|^{1/2} \exp \left\{ -\frac{1}{2}(x - \mu)' \Sigma^{-1} (x - \mu) \right\}$$

onde $|A|$ denota o determinante da matriz A . A distribuição normal padronizada é obtida quando $\mu = 0$ e $\Sigma = I_p$, a matriz identidade de ordem p . Nesse caso, as componentes x_i 's são normais padronizadas independentes. A distribuição normal univariada é o caso particular onde $p = 1$.

Densidade da Normal Bivariada

Exemplo:

$$\mu = [1, 1]; \Sigma = \begin{bmatrix} 1 & 0.5 \\ 0.5 & 1 \end{bmatrix}$$



Propriedades importantes

Transformações lineares

Se A é uma matriz $r \times p$ e b é um vetor r -dimensional então

$$y = Ax + b \sim N(A\mu + b, A\Sigma A')$$

Distribuições Marginais

Se o vetor x é dividido em 2 blocos x_1 contendo os primeiros r componentes de x e x_2 contendo os outros $p - r$ componentes então procedendo a mesma partição em μ e Σ na forma

$$\mu = \begin{pmatrix} \mu_1 \\ \mu_2 \end{pmatrix} \quad e \quad \Sigma = \begin{pmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma_{21} & \Sigma_{22} \end{pmatrix}$$

obtém-se que $x_i \sim N(\mu_i, \Sigma_{ii})$, $i = 1, 2$.

Distribuições condicionais

Mantendo as mesmas partições em x , μ e Σ obtém-se que

$$x_1 \mid x_2 \sim N(\mu_{1.2}, \Sigma_{11.2})$$

onde $\mu_{1.2} = \mu_1 + \Sigma_{12}\Sigma_{22}^{-1}(x_2 - \mu_2)$ e $\Sigma_{11.2} = \Sigma_{11} - \Sigma_{12}\Sigma_{22}^{-1}\Sigma_{21}$.

Resultados análogos são obtidos para a distribuição de $x_2 \mid x_1$ bastando a troca dos índices 1 e 2. Para esses resultados, é obviamente necessário que as submatrizes Σ_{22} e Σ_{11} respectivamente tenham posto máximo, caso contrário suas inversas não existem.

Reconstrução da conjunta

Se $x_1 \mid x_2 \sim N(\mu_1 + B_1(x_2 - \mu_2), B_2)$ e $x_2 \sim N(\mu_2, \Sigma_{22})$ então

$$\begin{aligned}x &= \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \sim N(\mu, \Sigma) \quad \text{com} \\ \mu &= \begin{pmatrix} \mu_1 \\ \mu_2 \end{pmatrix} \quad \text{e} \quad \Sigma = \begin{pmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma_{21} & \Sigma_{22} \end{pmatrix}\end{aligned}$$

onde $\Sigma_{11} = B_2 + B_1 \Sigma_{22} B_1'$ e $\Sigma_{21}' = \Sigma_{12} = B_1 \Sigma_{22}$.

Formas quadráticas

$$(x - \mu)' \Sigma^{-1} (x - \mu) \sim \chi_p^2$$


X tem **distribuição Gama** com parâmetros α e β se sua função de densidade for dada por:

$$p(x|\alpha; \beta) \propto x^{\alpha-1} \exp\{-\beta x\}, 0 < x < \infty.$$

Notação: $x \sim G(\alpha, \beta)$.

$$E(x) = \frac{\alpha}{\beta} \quad \text{e} \quad V(x) = \frac{\alpha}{\beta^2}$$

Densidade da Gama



Distribuição t-Student Univariada

X tem **distribuição t-Student univariada** com ν graus de liberdade, com parâmetros μ e σ se sua função densidade é dada por :


$$p(x|\mu, \sigma, \nu) \propto [\nu\sigma^2 + (x - \mu)^2]^{-(\nu+1)/2}, -\infty < x < \infty.$$

Quando $\mu = 0$ e $\sigma = 1$ diz-se que a variável aleatória tem distribuição t-Student padrão. Neste caso,


$$E(x) = \mu, \nu > 1 \quad \text{e} \quad V(x) = \frac{\nu}{\nu - 2}\sigma^2, \nu > 2.$$

Notação: $x \sim t_\nu(\mu, \sigma^2)$.

Densidade da t-student



Densidade da t-student



Observem as escalas dos gráficos!

\mathbf{x} ($n \times 1$) segue uma **distribuição t-multivariada** com parâmetros $\boldsymbol{\mu}$ e $\boldsymbol{\Sigma}$ e ν graus de liberdade, se sua função densidade é dada por:

$$p(\mathbf{x}|\boldsymbol{\mu}, \boldsymbol{\Sigma}, \nu) \propto [\nu + (\mathbf{x} - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu})]^{-(\nu+n)/2}$$

para $\mathbf{x} \in R^n$ onde $\boldsymbol{\mu} \in R^n$, $\boldsymbol{\Sigma} > 0$ ($n \times n$) e $\nu > 0$.

Notação: $\mathbf{x} \sim t_{\nu}(\boldsymbol{\mu}, \boldsymbol{\Sigma})$.

A média e variância de \mathbf{x} são :

$$\begin{aligned} E(\mathbf{x}) &= \boldsymbol{\mu} \quad \text{se } \nu > 1 \\ V(\mathbf{x}) &= \frac{\nu}{\nu - 2} \boldsymbol{\Sigma} \quad \text{se } \nu > 2. \end{aligned}$$

Diz-se que uma matriz $\mathbf{\Omega}$ segue uma **distribuição Wishart** com parâmetro $\mathbf{\Sigma}$ e ν graus de liberdade, se e só se, sua função densidade é dada por :

$$p(\mathbf{\Omega}|\mathbf{\Sigma}, \nu) \propto |\mathbf{\Omega}|^{(\nu-n-1)/2} \exp \left\{ -\frac{1}{2} \text{tr} \mathbf{\Sigma} \mathbf{\Omega} \right\}$$

onde $\nu \geq n$, $\mathbf{\Sigma} > 0$ ($n \times n$) e $\text{tr} \mathbf{\Sigma}$ é o traço da matriz $\mathbf{\Sigma}$.

Notação: $\mathbf{\Omega} \sim W(\mathbf{\Sigma}, \nu)$.

Wishart Invertida

Diz-se que uma matriz Ω ($n \times n$) segue uma **distribuição Wishart Invertida** com parâmetro Σ e ν graus de liberdade, se e só se, $\Omega^{-1} \sim W(\Sigma, \nu)$. Sua função densidade é dada por :

$$p(\Omega|\Sigma, \nu) \propto |\Omega|^{-(\nu+n+1)/2} \exp \left\{ -\frac{1}{2} \text{tr} \Sigma \Omega^{-1} \right\}$$

onde $\nu \geq n$, $\Sigma > 0$ ($n \times n$) e $\text{tr} \Sigma$ é o traço da matriz Σ .

Notação: $\Omega \sim WI(\Sigma, \nu)$

Algumas propriedades das distribuições citadas acima:

1. Se $\Omega \sim W(\Sigma, \nu) \Rightarrow \mathbf{A}\Omega\mathbf{A}' \sim W(\mathbf{A}\Sigma\mathbf{A}', \nu)$;
2. Se $\Omega^{-1} \sim WI(\Sigma, \nu) \Rightarrow \mathbf{A}\Omega\mathbf{A}' \sim WI(\mathbf{A}\Sigma\mathbf{A}', \nu)$;

Suponha que $X|Y \sim N(\mu, y^{-1}V)$ e $Y \sim G(\frac{\nu}{2}, \frac{d}{2})$
($\Leftrightarrow y^{-1} \sim GI(\frac{\nu}{2}, \frac{d}{2})$).

\Downarrow

$$(X, Y) \sim NG(\mu, V, \nu, d)$$

\Downarrow

$$X \sim t_{\nu}(\mu, SV) \text{ onde } S = \frac{d}{\nu}$$

Suponha que $X|Y \sim N(\mu, VY^{-1})$ e $Y \sim W(\Sigma, \nu)$

\Downarrow

$$(X, Y) \sim NW(\mu, V, \nu, \Sigma)$$

\Downarrow

$$X \sim t_\nu(\mu, \frac{V\Sigma}{\nu})$$

Introdução à inferência Bayesiana

Teorema de Bayes

Observações y : descritas por densidade ou função de probabilidade $f(y|\theta)$

Função de Verossimilhança y : $l(\theta) = f(y|\theta)$

Quantidade θ : indexador de f (parâmetro)

Situação canônica amostra aleatória simples $y = (y_1, \dots, y_n)$ é extraída de $f(y|\theta)$.

Exemplo 1 : medições sobre uma grandeza física θ com erros e_i descritos pela $N(0, \sigma^2)$, σ^2 é conhecida.

$$y_i = \theta + e_i, \quad i = 1, \dots, n \quad \text{e}$$

$$f(y|\theta) = \prod_{i=1}^n f_N(y_i; \theta, \sigma^2) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} \exp \left\{ -\frac{1}{2} \frac{(y_i - \theta)^2}{\sigma^2} \right\}$$

θ é mais do que um simples indexador. Essa situação se repete em casos mais gerais

É bastante provável que o pesquisador saiba caracterizar sua incerteza a respeito de θ probabilisticamente. Isso pode ser feito através de uma densidade $p(\theta)$

Teorema de Bayes

Processo de inferência baseado na distribuição de θ após observar y .

→ distribuição a posteriori (em oposição à priori)

Obtida através do teorema de Bayes via

$$p(\theta|y) = \frac{f(y|\theta)p(\theta)}{f(y)} \quad \text{ou}$$

$$\pi(\theta) \propto l(\theta) p(\theta)$$

$$f(y) = \int f(y|\theta)p(\theta)d\theta$$

Teorema de Bayes para Variáveis Normais

Exemplo 1 (cont.) : o modelo pode ser completado com priori $p(\theta) = N(\mu, \tau^2)$, μ e τ^2 conhecidos.

$$l(\theta) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} \exp \left\{ -\frac{1}{2} \frac{(y_i - \theta)^2}{\sigma^2} \right\} \propto \exp \left\{ -\frac{n}{2\sigma^2} (\bar{y} - \theta)^2 \right\}$$

onde \bar{y} é a média aritmética dos y_i 's.

$$\pi(\theta) \propto \exp \left\{ -\frac{1}{2} \frac{(\theta - \mu_1)^2}{\tau_1^2} \right\}$$

onde $\boxed{\tau_1^{-2} = n\sigma^{-2} + \tau^{-2}}$ e $\boxed{\mu_1 = \tau_1^2(n\sigma^{-2}\bar{y} + \tau^{-2}\mu)}$

portanto: $\pi(\theta) = N(\mu_1, \tau_1^2)$.

- $\tau^2 \rightarrow \infty$: priori não-informativa $p(\theta) \propto \text{cte.}$ e

$$\pi(\theta) = N(\bar{y}, \sigma^2/n)$$

- Sabe-se que o nível de glicose em uma pessoa normal pode ser descrito pela distribuição $N(120, 100)$, i.e,

$$p(\mu) = \frac{1}{\sqrt{200\pi}} \exp \left\{ -\frac{1}{2} \left(\frac{\mu - 120}{10} \right)^2 \right\}$$

Logo, $Pr(\mu \text{ estar entre } 100 \text{ e } 140) = 0,95$

- Uma medição, y , em laboratório é feita. Vamos supor que $\{y|\mu\}$ é $N(\mu, 25)$, i.e.

$$f(y|\mu) = \frac{1}{\sqrt{50\pi}} \exp \left\{ -\frac{1}{2} \left(\frac{y - \mu}{5} \right)^2 \right\}$$

daí, as chances da medição errar o nível em mais de 10 ml são de 5%

- ✓ A amostra é colhida e a **medição observada é de 127 ml**.
- ✓ Agora, nossa incerteza sobre o nível de glicose é dado por

$$\begin{aligned} p(\mu|y = 127) &\propto f(127|\mu)p(\mu) \\ &\propto \exp\left\{-\frac{1}{2}\left(\frac{127 - \mu}{5}\right)^2\right\} \exp\left\{-\frac{1}{2}\left(\frac{\mu - 120}{10}\right)^2\right\} \\ &\propto \exp\left\{-\frac{1}{2}\left(\frac{\mu - 125.6}{4.5}\right)^2\right\} \end{aligned}$$

Logo, $(\mu|y = 127)$ é $N(125.6, (4.5)^2)$ e $Pr(116.6 < \mu < 134.6) = 0.96$

Exemplo 2 : Vamos supor agora que a **variância** da observação também é **desconhecida**. Nosso modelo passa a ser

$$\begin{aligned}(y \mid \theta, \sigma^2) &\sim N(\theta, \sigma^2) \\ (\theta \mid \sigma^2) &\sim N(a, \sigma^2 R)\end{aligned}$$

Nosso parâmetro agora é bidimensional e para completar a distribuição a priori precisamos de uma distribuição marginal para σ^2 .

Por conveniência especificamos a priori para $\phi = \sigma^{-2}$ como $\phi \sim G\left(\frac{n}{2}, \frac{d}{2}\right)$
 $\Leftrightarrow \sigma^2 \sim GI\left(\frac{n}{2}, \frac{d}{2}\right)$. Logo $(\theta, \phi) \sim NG(a, R, n, d)$.

Daí, aplicando o teorema de Bayes obtemos

$$\begin{aligned} f(\theta, \phi|y) &\propto f(y|\theta, \phi)p(\theta, \phi) \\ &\propto \phi^{[(n+2)/2]-1} \exp \left\{ -\frac{\phi}{2} \left[\frac{(\theta - m)^2}{C} + \frac{(y - a)^2}{R+1} + d \right] \right\} \end{aligned}$$

$$f(\theta|\phi, y) \propto \exp \left\{ -\frac{\phi}{2} \frac{(\theta - m)^2}{C} \right\},$$

assim $(\theta|\phi, y) \sim N(m, C/\phi) = N(m, \sigma^2 C)$

$$(\phi|y) \sim G \left(\frac{n+1}{2}, \frac{1}{2} \left[d + \frac{(y-a)^2}{R+1} \right] \right)$$

Logo, $(\theta, \phi|y) \sim NG \left(m, C, n+1, d + \frac{(y-a)^2}{R+1} \right)$.

Como $y = \theta + \epsilon$ onde $(\epsilon|\sigma^2) \sim N(0, \sigma^2)$ obtemos que

$$\begin{aligned}E(y|\sigma^2) &= E(\theta|\sigma^2) + E(\epsilon|\sigma^2) = a \\V(y|\sigma^2) &= V(\theta|\sigma^2) + V(\epsilon|\sigma^2) = \sigma^2(R + 1)\end{aligned}$$

Logo $y|\phi \sim N(a, \frac{R+1}{\phi})$

$\Rightarrow (y, \phi) \sim NG(a, (R + 1), n, d)$

$\Rightarrow y \sim t_n(a, \frac{d}{n}(R + 1))$

- **Priori não-informativa:** muita controvérsia entre Bayesianos
 \Rightarrow Variância grande
- Previsão de uma observação futura y após observar x

$$f(y|x) = \int f(y, \theta|x) d\theta = \int f(y|\theta) \pi(\theta) d\theta$$

se y e x são independentes condicionalmente a θ

- No caso multivariado: $\theta = (\theta_1, \dots, \theta_p)$
- Densidade marginal a posteriori de θ_i é dada por

$$\pi(\theta_i) = \int \pi(\theta_1, \dots, \theta_p) d\theta_{-i}$$

onde $\theta_{-i} = (\theta_1, \dots, \theta_{i-1}, \theta_{i+1}, \dots, \theta_p)$

- Para cada θ_i : profusão de distribuições condicionais


Sumarizadores importantes da posteriori:

- 1 **locação**: média, moda e mediana
- 2 **dispersão**: variância, desvio-padrão, precisão e curvatura na moda

Em geral, expressão da posteriori é muito complexa:
impossível obtenção analítica dessas quantidades

Exemplo priori é alterada da normal para a Cauchy

$$\pi(\theta) \propto \exp \left\{ -\frac{1}{2} \frac{(\bar{y} - \theta)^2}{\sigma^2/n} \right\} \frac{1}{\tau^2 + (\theta - \mu)^2}$$



Modelos de Regressão

Num modelo de regressão temos uma variável resposta y que é explicada por um conjunto de variáveis explicativas x_1, \dots, x_p através da relação


$$y = \beta_0 + \beta_1 x_1 + \dots + \beta_p x_p + v$$

Em geral, assume-se que o v tem distribuição $N(0, \sigma^2)$. A equação acima pode ser mais compactamente escrita como:

$$y = \mathbf{x}'\boldsymbol{\beta} + v,$$

$$\text{onde: } \mathbf{x} = \begin{pmatrix} 1 \\ x_1 \\ \vdots \\ x_p \end{pmatrix} \quad \text{e} \quad \boldsymbol{\beta} = \begin{pmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_p \end{pmatrix}$$

Modelos de Regressão



- A natureza das variáveis explicativas ou regressores é bastante ampla. Podendo assim, utilizar-se qualquer variável quantificável.
- Os coeficientes de regressão β_1, \dots, β_p informam sobre a influência que os regressores têm sobre a resposta y .
- Na prática, seus valores são desconhecidos e estimados a partir de uma coleção de observações feitas sobre o modelo acima. Assim, observamos respostas y_1, \dots, y_n com seus respectivos regressores x_1, \dots, x_n . Simbolicamente, temos:

$$y_t = \mathbf{x}_t' \beta + v_t, \quad t = 1, \dots, n.$$

Modelo Bayesiano completado com priori conjugada para β e $\phi = \sigma^{-2}$

$$\beta|\phi \sim N(b_0, \phi^{-1}B_0) \quad e \quad \phi \sim G\left(\frac{n_0}{2}, \frac{n_0 S_0}{2}\right)$$

Aplicando o teorema de Bayes, vem a posteriori

$$\beta|\sigma^2 \sim N(b_1, \sigma^2 B_1) \quad e \quad \sigma^2 \sim GI\left(\frac{n_1}{2}, \frac{n_1 S_1}{2}\right)$$

Detalhes de modelos de regressão

Estimação de máxima verossimilhança

Os estimadores de MV de β e σ^2 no modelo de regressão são

$$\begin{aligned}\hat{\beta} &= (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{y} \\ \hat{\sigma}^2 &= \frac{1}{n}\mathbf{y}'(\mathbf{I} - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}')\mathbf{y}\end{aligned}$$

mas $S^2 = n\hat{\sigma}^2/(n-p)$ é o estimador não-viciado de σ^2 .

Suas distribuições amostrais são dadas por

$$\begin{aligned}\hat{\beta} &\sim t_{n-p}(\beta, S^2(\mathbf{X}'\mathbf{X})^{-1}) \text{ e} \\ (n-p)\frac{S^2}{\sigma^2} &\sim \chi_{n-p}^2 \Leftrightarrow S^2 \sim G\left(\frac{n-p}{2}, \frac{n-p}{2}\sigma^2\right)\end{aligned}$$

Estimação Bayesiana

Os parâmetros da distribuição a posteriori de β e σ^2 são

$$\begin{aligned} \mathbf{b}_1 &= \mathbf{B}_1(\mathbf{B}_0^{-1}\mathbf{b}_0 + \mathbf{X}'\mathbf{y}) \\ \mathbf{B}_1^{-1} &= \mathbf{B}_0^{-1} + \mathbf{X}'\mathbf{X} \\ n_1 &= n_0 + n \\ n_1 S_1 &= n_0 S_0 + (n - p)S^2 + (\hat{\beta} - \mathbf{b}_0)'[\mathbf{B}_0 + (\mathbf{X}'\mathbf{X})^{-1}]^{-1}(\hat{\beta} - \mathbf{b}_0) \end{aligned}$$

Se a priori é não-informativa ($n_0 \rightarrow 0$ e $\mathbf{B}_0^{-1} \rightarrow \mathbf{0}$) então

$$\mathbf{b}_1 = \hat{\beta}, \mathbf{B}_1 = (\mathbf{X}'\mathbf{X})^{-1}, n_1 = n - p \text{ e } n_1 S_1 = (n - p)S^2$$

As expressões das distribuições a posteriori são

$$\begin{aligned} \beta &\sim t_{n-p}(\hat{\beta}, S^2(\mathbf{X}'\mathbf{X})^{-1}) \text{ e} \\ (n-p)\frac{S^2}{\sigma^2} &\sim \chi_{n-p}^2 \Leftrightarrow \sigma^2 \sim Gl\left(\frac{n-p}{2}, \frac{n-p}{2}S^2\right) \end{aligned}$$