

## Aplicação da Abordagem Bayesiana

### *Modelo Gerativo para os Campos Receptivos*

- **Inferência Bayesiana:**

→ Usada para estimação dos atributos  $X$  a partir dos observáveis  $Y$

→ Incorpora um *modelo do mundo* e um *modelo de geração*:  $Pr[X]$ ,  $Pr[Y|X]$

*Regra de Bayes:*

$$Pr[X, Y] = Pr[X|Y]Pr[Y] = Pr[Y|X]Pr[X]$$

Daí,

$$Pr[X|Y] = \frac{Pr[X]Pr[Y|X]}{Pr[Y]} \equiv \frac{Pr[X]Pr[Y|X]}{\sum_X Pr[X]Pr[Y|X]}$$

→ Atributos podem ser estimados maximizando-se  $Pr[X|Y]$

*Modelo Gerativo para os CR:*

$X$ : Campos receptivos corticais;  $Y$ : Imagens naturais

- *Modelo de Formação das Imagens*

Em uma pequena região:

$$I(\mathbf{x}) = \sum_i a_i \phi_i(\mathbf{x}) + \nu(\mathbf{x})$$

$\phi_i(\mathbf{x})$ : Campo Receptivo

$\nu(\mathbf{x})$ : Ruído (tudo o que não é descrito pelo modelo)

Assumindo ruído Gaussiano *i.i.d.*, com variância  $1/\lambda_N$ , em cada ponto:

$$Pr[\mathbf{I}|\mathbf{a}] = \Pi_{\mathbf{x}} \left\{ \sqrt{\frac{\lambda_N}{2\pi}} e^{-\frac{\lambda_N}{2} [I(\mathbf{x}) - \sum_i a_i \phi_i(\mathbf{x})]^2} \right\}$$

ou seja,

$$Pr[\mathbf{I}|\mathbf{a}] = \frac{1}{Z_N} e^{-\frac{\lambda_N}{2} \sum_{\mathbf{x}} [I(\mathbf{x}) - \sum_i a_i \phi_i(\mathbf{x})]^2}$$

com  $\mathbf{I} = \{I(\mathbf{x})\}$ ,  $\mathbf{a} = \{a_i\}$

- *Modelo do Mundo*

Assumimos que os CRs proporcionam uma *representação esparsa*

→ A maior parte dos  $a_i$  deve ser zero

→  $Pr[\mathbf{a}]$  deve ser uma função *concentrada na origem*, com *decaimento lento*

→ Escolhemos variáveis *i.i.d.* de *Cauchy*

$$Pr[\mathbf{a}] = \Pi_i \left\{ \frac{1}{\lambda_S(1 + a_i^2)} \right\}$$

ou seja,

$$Pr[\mathbf{a}] = \frac{1}{Z_S} e^{-\sum_i S(a_i)}$$

onde

$$S(a_i) = \log(1 + a_i^2)$$

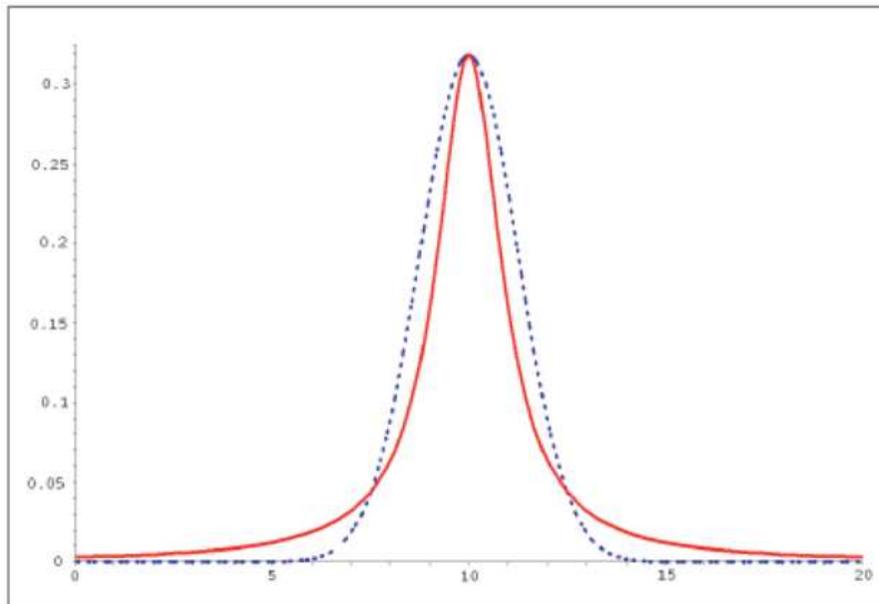
*Regra de Bayes:*

$$Pr[\mathbf{a}|\mathbf{I}] \propto Pr[\mathbf{I}|\mathbf{a}]Pr[\mathbf{a}]$$

*Função Densidade de Cauchy:*

$$f(x) = \frac{b}{\pi[(x - x_0)^2 + b^2]}$$

Cauchy X Gaussiana



→ Pico mais estreito

→ Cauda mais larga

→ Média e variância não estão definidas

- *Estimação*

→ Precisamos obter os CRs,  $\phi_i(\mathbf{x})$ , e os pesos,  $a_i$

i) Supondo conhecidos os CRs,

→ Obtemos os pesos  $a_i$  maximizando  $Pr[\mathbf{a}|\mathbf{I}]$ :

Empregamos *subida gradiente* sobre  $\log Pr[\mathbf{a}|\mathbf{I}]$

$$\Delta a_i = \frac{\partial}{\partial a_i} \log Pr[\mathbf{a}|\mathbf{I}]$$

ou seja,

$$\Delta a_i = b_i - \sum_j C_{ij} a_j - S'(a_i)$$

onde

$$b_i = \lambda_N \sum_{\mathbf{x}} \phi_i(\mathbf{x}) I(\mathbf{x})$$

$$C_{ij} = \lambda_N \sum_{\mathbf{x}} \phi_i(\mathbf{x}) \phi_j(\mathbf{x})$$

$$S'(a_i) = \frac{d}{da_i} S(a_i)$$

→ Obtidos os  $a_i$ , podemos calcular

$$Pr[\mathbf{I}] = \sum_{\mathbf{a}} Pr[\mathbf{I}|\mathbf{a}] Pr[\mathbf{a}]$$

ii) Obtemos os CRs maximizando  $Pr[\mathbf{I}]$

→ Empregamos *subida gradiente* sobre  $\langle \log Pr[\mathbf{I}|\mathbf{a}] \rangle$

onde  $\langle \rangle$  indica valor médio sobre todas as imagens

Assim,

$$\Delta\phi_i(\mathbf{x}) = \frac{\partial}{\partial\phi_i(\mathbf{x})} \langle \log Pr[\mathbf{I}|\mathbf{a}] \rangle$$

ou seja,

$$\Delta\phi_i(\mathbf{x}) = \lambda_N \langle a_i[I(\mathbf{x}) - \sum_i a_i\phi_i(\mathbf{x})] \rangle$$

→ Passos *i* e *ii* são repetidos iterativamente, partindo de CRs aleatórios

→ *CRs estimados são compatíveis com os neurofisiológicos*

