3 - Formas de Aplicação do Treinamento BP

Processo em

Batelada – Batch

Lotes

Regra Delta - para treinamento “on line”, dinâmico

Regra delta com momento

Todos os dados disponíveis

Sistema invariante no tempo

Processo em

Batelada – Batch

Lotes

Batelada - Algorítmo

Inicializar $n = 1;\ \alpha = .1;\ w_i(1) \in [+.2, -.2]$ *randômicos*

Até que o critério de parada seja satisfeito

para cada par ($\underline{x}^p$, $\underline{y}^p$) p = 1, …, P

calcular o acréscimo Δw_{ij}^p nas sinapses devido ao par p:
(ver algorítmo no cap. 2 Treinamento BP)

$$\underline{\tilde{y}}^p = \varphi\left(\underline{x}^p\right)$$

$$\varepsilon_m^p = y_m^p - \tilde{y}_m^p \quad \text{e} \quad \frac{\partial \tilde{y}_m^p}{\partial w_{ij}} \quad \forall\, m, i, j$$

$$\Delta w_{ij}^p = -\alpha \frac{\partial \varepsilon^{p2}}{\partial w_{ij}} = 2\alpha \sum_{m=1}^{M} \varepsilon_m^p \frac{\partial y_m^p}{\partial w_{ij}} \quad \forall\, i, j$$

outro par

calcular os acréscimos e atualizar as sinapses

$$\Delta w_{ij}(n) = \underset{p}{E}\, \Delta w_{ij}^p \qquad w_{ij}(n+1) = w_{ij}(n) + \Delta w_{ij}(n) \qquad \forall i, j$$

n = n+1

fim do algorítmo

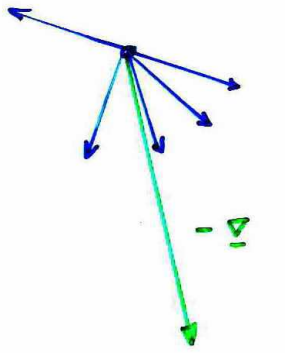

se P >> (P > ~ 200)

⇒ **muito lento**

Processo por Lotes

Se P > ~200

Alocar os pares entrada-saída aleatoriamente em C conjuntos,

$C \approx P / 200$

Algorítmo

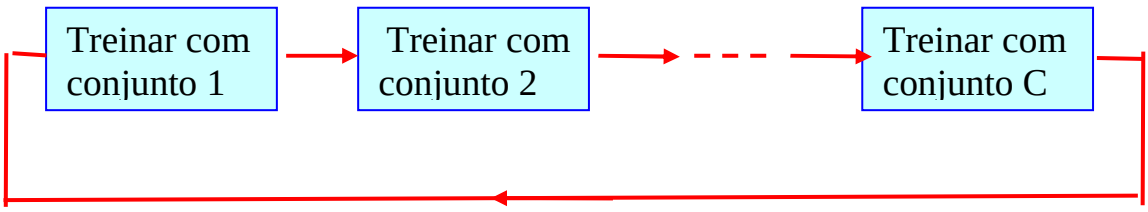

Lotes - Algorítmo

Inicializar $n = 1; \alpha = .1;\ w_i(1) \in [+.2, -.2]$ *randômicos*

Até que o critério de parada seja satisfeito

Treinar (em batelada, sem reinicializar) usando os pares do conjunto 1

Treinar (em batelada, sem reinicializar) usando os pares do conjunto 2

...

Treinar (em batelada, sem reinicializar) usando os pares do conjunto C

fim do algorítmo

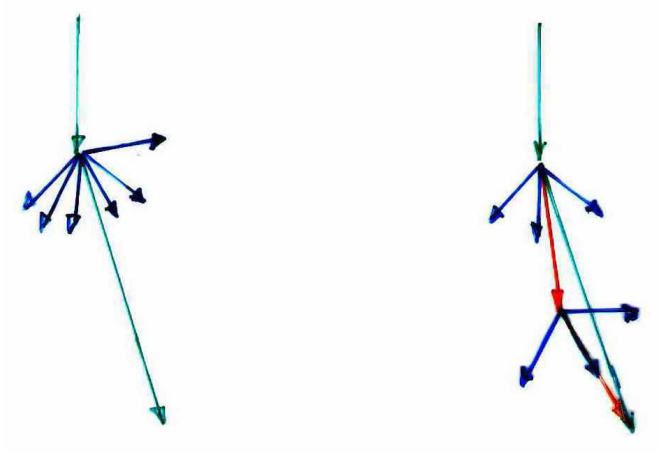

batelada lotes

reduz o tempo

preserva a generalização

mantém a estabilidade do treinamento

Dados em fluxo e/ou

Sistema variante no tempo

Regra Delta - treinamento “on line”, dinâmico

Regra delta com momento

Processo Regra Delta - uso “on line”

Atualiza as sinapses a cada par entrada-saída apresentado

o acréscimo nas sinapses é aplicado após cada par entrada-saída ser apresentado - é como usar lotes com um único par.

Treinamento adaptativo para sistemas variantes no tempo

Regra Delta - Algorítmo

Inicializar $n=1;\ \alpha=.1;\ w_i(1) \in [+.2,-.2]$ *randômicos*

Até que o critério de parada seja satisfeito

para cada par $(\underline{x}^p, \underline{y}^p)$ p = 1, …, P

calcular o acréscimo Δw_{ij}^p nas sinapses devido ao par p:

(ver algorítmo no cap. 2 Treinamento BP)

$$\underline{\tilde{y}}^p = \varphi\left(\underline{x}^p\right)$$

$$\varepsilon_m^p = y_m^p - \tilde{y}_m^p \quad \text{e} \quad \frac{\partial \tilde{y}_m^p}{\partial w_{ij}} \quad \forall\ m, i, j$$

$$\Delta w_{ij}^p = -\alpha \frac{\partial \varepsilon^{p2}}{\partial w_{ij}} = 2\alpha \sum_{m=1}^{M} \varepsilon_m^p \frac{\partial y_m^p}{\partial w_{ij}} \quad \forall\ i, j$$

atualizar as sinapses

$$w_{ij}(n+1) = w_{ij}(n) + \Delta w_{ij}^p \quad \forall i, j$$

n = n+1

outro par

fim do algorítmo

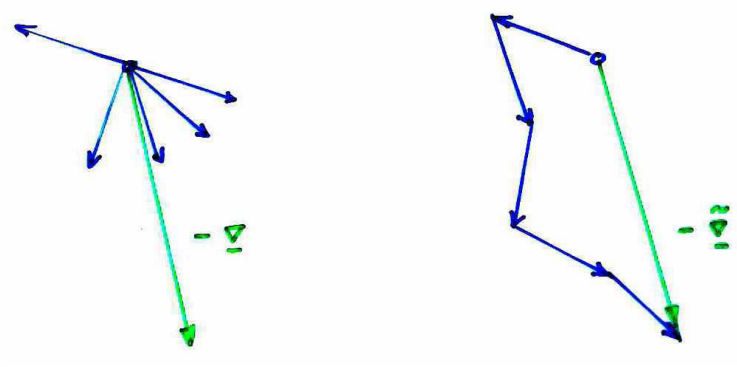

batelada regra delta

muito rápido, mas F oscila !

normalmente usado com momento

Treinamento com Momento

Regra delta: $$\Delta w_{i_D}(n) = 2\alpha \sum_{l=1}^{m} \varepsilon_l \frac{\partial \tilde{y}_l}{\partial w_i}$$

Momento $\Delta w_i(n) = \beta \Delta w_i(n-1) + (1-\beta) \Delta w_{i_D}(n)$

$\beta_{\text{típico}} \approx .9$

Intermediário entre treinamento regra delta e treinamento por lotes.

Cada “lote” é constituído pelos últimos

$N_0 \approx \frac{4}{1-\beta}$ pares aplicados.

Compensa a “instabilidade” do processo regra delta

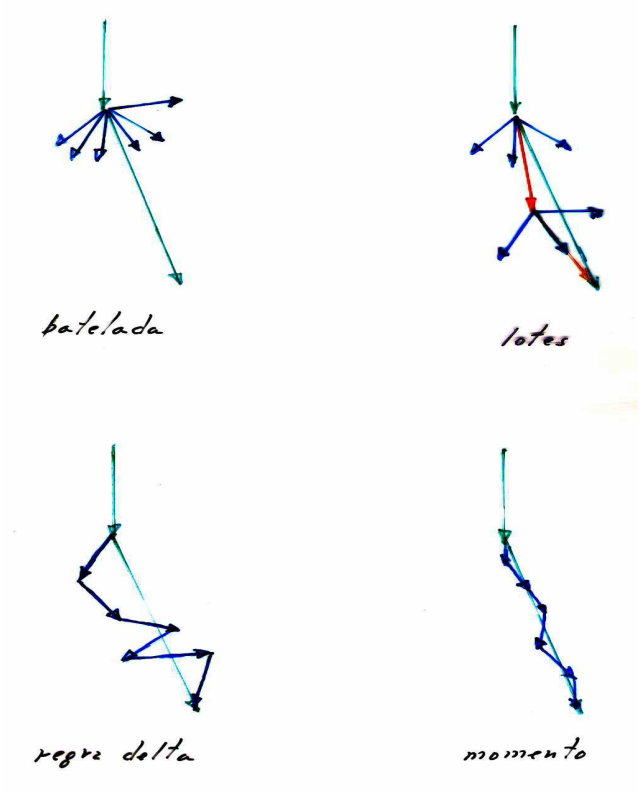

Regra Delta com Momento - Algorítmo

Inicialização n=1; $\alpha = .1$ $\beta = .9$ $\Delta w_i^{RD}(0) = 0 \quad \forall\, i$

para as i = 1, 2, …, V variáveis $w_i(1) \in [+.2, -.2]$ randômicos;

Até que o critério de parada seja satisfeito

para cada par ($\underline{x}^p$, $\underline{y}^p$) p = 1, …, P

calcular o acréscimo por regra delta (BP)

(ver algorítmo anterior)

$$\underline{\tilde{y}}^p = \varphi\left(\underline{x}^p\right)$$

$$\varepsilon_m^p = y_m^p - \tilde{y}_m^p \quad \text{e} \quad \frac{\partial \tilde{y}_m^p}{\partial w_i} \quad \forall\, m, i$$

$$\Delta w_i^{RD}(n) = 2\alpha \sum_{m=1}^{M} \varepsilon_m^p \frac{\partial y_m^p}{\partial w_i} \qquad \forall\, i$$

calcular e aplicar o acréscimo com momento

$$\Delta w_i(n) = \beta \Delta w_i(n-1) + (1-\beta)\Delta w_i^{RD}(n) \quad \forall\, i$$

$$w_i(n+1) = w_i(n) + \Delta w_i(n) \qquad \forall i$$

n=n+1

outro par

fim do algorítmo

Detalhes do treinamento Regra Delta com momento

n = 1 $\Delta w_D(1)$

$\Delta w(1) = \beta\, \Delta w(0) + (1-\beta)\, \Delta w_D(1)$

$= (1-\beta)\ \Delta w_D(1)$

n = 2 $\Delta w_D(2)$

$\Delta w(2) = \beta\, \Delta w(1) + (1-\beta)\, \Delta w_D(2) =$

$= \beta(1-\beta)\, \Delta w_D(1) + (1-\beta)\, \Delta w_D(2)$

n = 3 $\Delta w_D(3)$

$\Delta w(3) = \beta\, \Delta w(2) + (1-\beta)\, \Delta w_D(3) =$

$= \beta^2(1-\beta)\, \Delta w_D(1) + \beta(1-\beta)\, \Delta w_D(2) + (1-\beta)\, \Delta w_D(3)$

n = 4 $\Delta w_D(4)$

$\Delta w(4) = \beta^3(1-\beta)\, \Delta w_D(1) + \beta^2(1-\beta)\, \Delta w_D(2) + \beta(1-\beta)\, \Delta w_D(3)$

$+ (1-\beta)\, \Delta w_D(4)$

…

n $\Delta w_D(n)$

$\Delta w(n) = \beta^{n-1}(1-\beta)\, \Delta w_D(1) + \beta^{n-2}(1-\beta)\, \Delta w_D(2) + \ldots$

$\ldots + \beta^{n-1}(1-\beta)\, \Delta w_D(i) + \ldots + (1-\beta)\, \Delta w_D(n)$

$$\Delta w(n) = (1-\beta) \sum_{i=1}^{n} \Delta w_D(i)\ \beta^{n-i}$$

Contribuições em cada passo:

Média ponderada exponencialmente pelo atraso (n-i)

(n – i) = atraso da i-ésima entrada em relação ao instante atual n

No passo n

$$\Delta w(n) = (1-\beta) \sum_{i=1}^{n} \Delta w_D(i)\ \beta^{n-i}$$

$$\beta^{n-i} = e^{(n-i)\ln\beta} = e^{-\frac{(n-i)}{\tau}}$$

$$\tau = -\frac{1}{\ln\beta} \approx \frac{1}{1-\beta} \qquad \text{se } \beta \approx 1$$

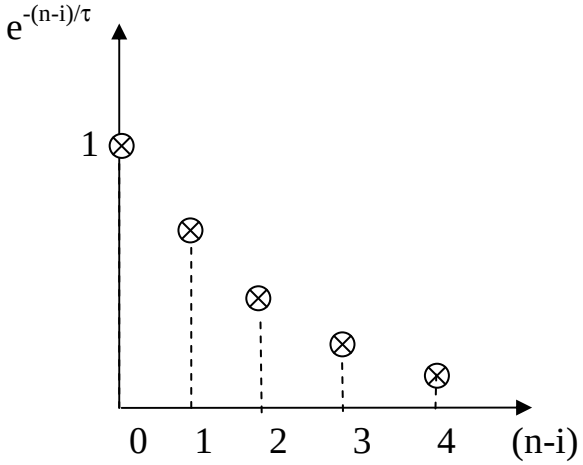

$$\Delta w(n) = (1-\beta) \sum_{i=1}^{n} \Delta w_D(i)\ e^{-(n-i)/\tau}$$

média ponderada exponencialmente pelo atraso

Contribuições significativas: peso > .02 $\Longrightarrow$ n-i < 4 τ

Máximo atraso significativo (lote significativo):

$$N_0 \cong 4\tau \cong \frac{4}{1-\beta}$$

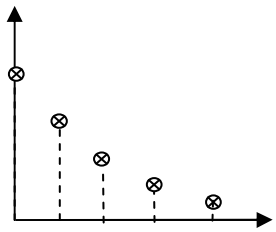

Contribuição total de $\Delta w_D(n)$:

$$\Delta w_D(n)\ (1-\beta)\ (1 + \beta + \beta^2 + \ldots) =$$

$$= \Delta w_D(n)\ (1-\beta)\ \frac{1}{1-\beta} = \mathbf{\Delta w_D(n)}$$