

Métodos de otimização mais eficientes

Otimização via Métodos Numéricos Recursivos

$$\underline{w} \rightarrow \underline{w} + \underline{\Delta w} \quad | \quad F(\underline{w} + \underline{\Delta w}) < F(\underline{w})$$

$\underline{\Delta w}$??


$$\underline{\Delta w} = \alpha \underline{d}$$

Passo
controla $|\underline{\Delta w}|$
 $\alpha > 0$, pequeno

controla
direção $\underline{\Delta w}$


1 - Passo variável, otimizado

Passo ótimo ? otimização em linha




Passo variável por sinapse

α diferenciado por sinapse



Passo variável por ponto de operação

α diferenciado por passo de treinamento



1.1 - Resilient Backpropagation (modificado)

(Silva e Almeida, Super SAB, etc.)

$$\alpha \text{ variável} \begin{cases} \text{por variável } w_i \\ \text{por passo de treinamento } n \end{cases}$$

$$\Delta w_i(n) = - \alpha_i(n) \frac{\partial F}{\partial w_i}(n)$$


$$\alpha_i(n) = \begin{cases} a \alpha_i(n-1) & \text{se } \text{sign} \frac{\partial F}{\partial w_i}(n) = \text{sign} \frac{\partial F}{\partial w_i}(n-1) \\ b \alpha_i(n-1) & \text{se } \text{sign} \frac{\partial F}{\partial w_i}(n) \neq \text{sign} \frac{\partial F}{\partial w_i}(n-1) \end{cases}$$

se $\alpha_i(n) > \alpha^*$ faça $\alpha = \alpha^*$

$$\alpha_i(0) \approx .05 \quad \alpha^* \approx .2 \quad a \approx 1.05 \quad b \approx .9$$

Outra alternativa

$$b = \frac{\frac{\partial F}{\partial w_i}(n-1)}{\frac{\partial F}{\partial w_i}(n-1) - \frac{\partial F}{\partial w_i}(n)}$$



BP Resiliente - Algoritmo

Inicialização

$$n = 1 \quad \alpha_{\max} \approx .5 \quad a \approx 1.05$$

para as $i = 1, 2, \dots, V$ variáveis

$$w_i(1) \in [+.2, -.2] \text{ randômicos; } \alpha_i(1) = .1 \quad \frac{\partial F}{\partial w_i}(0) = 0$$

Até que o critério de parada esteja satisfeito

Passo de treinamento n **BP Resiliente - Algoritmo (continuação)**

Cálculo do gradiente

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

$$\text{calcular} \quad \underline{\tilde{y}}^p = \varphi(\underline{x}^p)$$

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

$$\frac{\partial \varepsilon^{p2}}{\partial w_i} = -2 \sum_{m=1}^M \varepsilon_m^p \frac{\partial y_m^p}{\partial w_i} \quad \forall i$$

outro par

$$\text{calcular} \quad \frac{\partial F}{\partial w_i}(n) = E_P \frac{\partial \varepsilon^{p2}}{\partial w_i}$$

BP Resiliente - Algoritmo (continuação)

Cálculo do acréscimo

para $i = 1, 2, \dots, V$

$$\alpha_i(n) = \begin{cases} \alpha_i(n-1) & \text{se } \text{sign} \frac{\partial F}{\partial w_i}(n) = \text{sign} \frac{\partial F}{\partial w_i}(n-1) \\ & \text{mas se } \alpha_i(n) > \alpha_{\max} \text{ faça } \alpha_i(n) = \alpha_{\max} \\ \frac{\frac{\partial F}{\partial w_i}(n-1)}{\frac{\partial F}{\partial w_i}(n-1) - \frac{\partial F}{\partial w_i}(n)} \alpha_i(n-1) & \text{se } \text{sign} \frac{\partial F}{\partial w_i}(n) \neq \text{sign} \frac{\partial F}{\partial w_i}(n-1) \end{cases}$$

$$\Delta w_i(n) = - \alpha_i(n) \frac{\partial F}{\partial w_i}(n)$$


$$w_i(n+1) = w_i(n) + \Delta w_i(n)$$

$n = n + 1$

1.2 - Métodos de 1ª. Ordem (Resumo)

$$\underline{w}_{n+1} = \underline{w}_n + \alpha_n \underline{d}_n$$

$$\underline{d}_n^t = - \underline{\nabla}_n$$




BP : α constante

BP Resiliente: α variável por sinapse e por passo

2 - Métodos de Segunda Ordem

Passo variável, otimizado ϵ

Melhores direções de deslocamento



Métodos de primeira ordem dependem de

$$\underline{\Delta w} = \Delta w_i \quad \left[\nabla F(\underline{w}_0) = \frac{\partial F}{\partial w_i} \Big|_{\underline{w}_0} \right] \quad \text{gradiente}$$

Métodos de segunda ordem dependem também de

$$\underline{H}(\underline{w}_0) = \left[\frac{\partial^2 F}{\partial w_i \partial w_j} \Big|_{\underline{w}_0} \right] \quad \text{Hessiana}$$

ou de suas aproximações

MÉTODOS DE SEGUNDA ORDEM: MAIS SOFISTICADOS / MAIS EFICIENTES (?)


Newton	$\underline{\mathbf{H}}$	
Newton Amortecido	$\approx \underline{\mathbf{H}}$	Levenberg – Marquadt
Quasi Newton	$\approx \underline{\mathbf{H}}^{-1}$	BFGS
Gradiente Conjugado		Fletcher – Reeves

Métodos de 2ª. Ordem (Resumo)

$$\underline{\mathbf{w}}_{n+1} = \underline{\mathbf{w}}_n + \alpha_n \underline{\mathbf{d}}_n$$

$$\alpha_n = \underset{\alpha_n > 0}{\text{Arg}} [\text{Min } F(\underline{\mathbf{w}}_n + \alpha_n \underline{\mathbf{d}})] \text{ otimização em linha}$$

$$\underline{\mathbf{d}}_n \quad ???$$



Referências bibliográficas principais:

Cichocki, Unbehauen – “Neural Networks for Optimization and Signal Processing”, Cap. 1 e 3, Wiley, 1993.

Chong, Zak – “An Introduction to Optimization”, Part II, Wiley, 2001.

Addy, Dempster – “Introduction to optimization methods”, Chapman and Hall, 1974.