

## 6 – Treinamento:

### 6.1 Superfícies de Erro

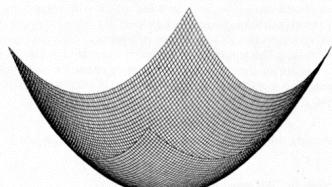


Fig. 22. Example MSE surface of linear error.



Fig. 23. Example MSE surface of sigmoid error.

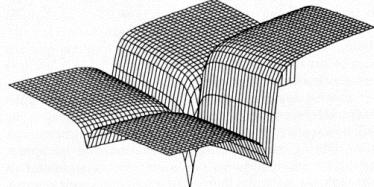
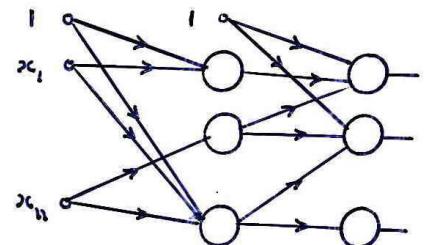


Fig. 30. Example MSE surface of trained sigmoidal network as a function of two first-layer weights.

Mínimos locais possíveis ? SIM !

Vários mínimos globais

Comparação de soluções:  
somente via erro



### 6.2 - Evolução do Erro durante o treinamento

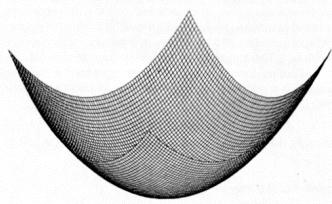


Fig. 22. Example MSE surface of linear error.



Fig. 23. Example MSE surface of sigmoid error.

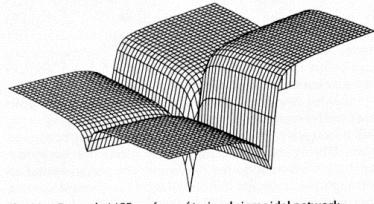
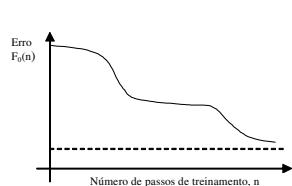
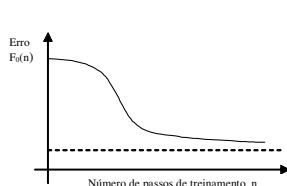
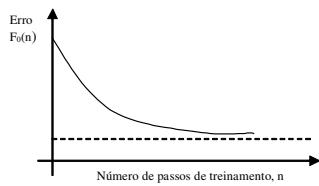
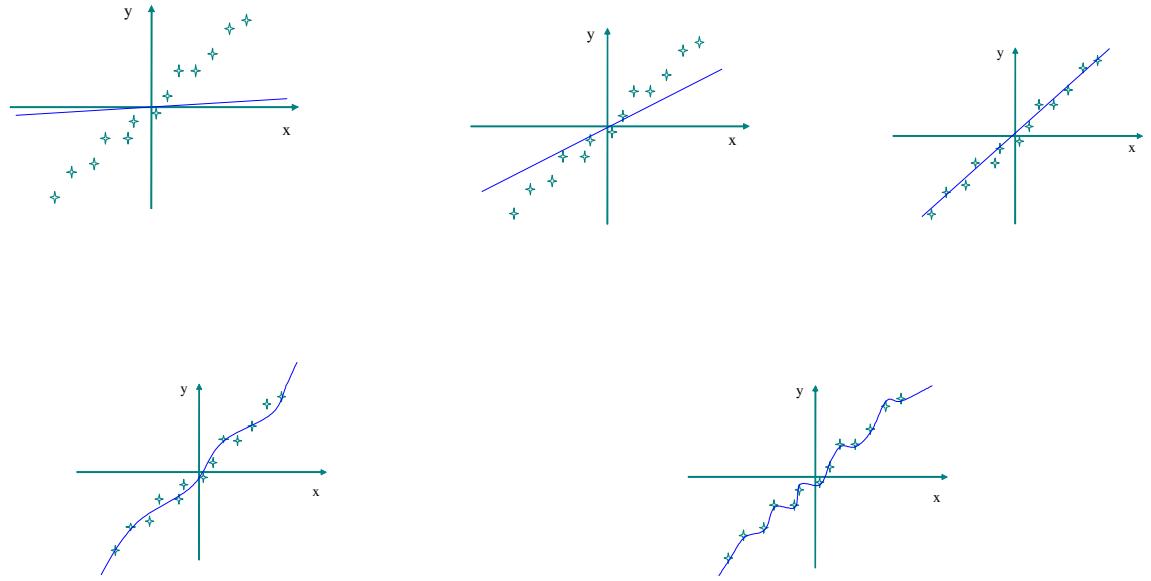


Fig. 30. Example MSE surface of trained sigmoidal network as a function of two first-layer weights.



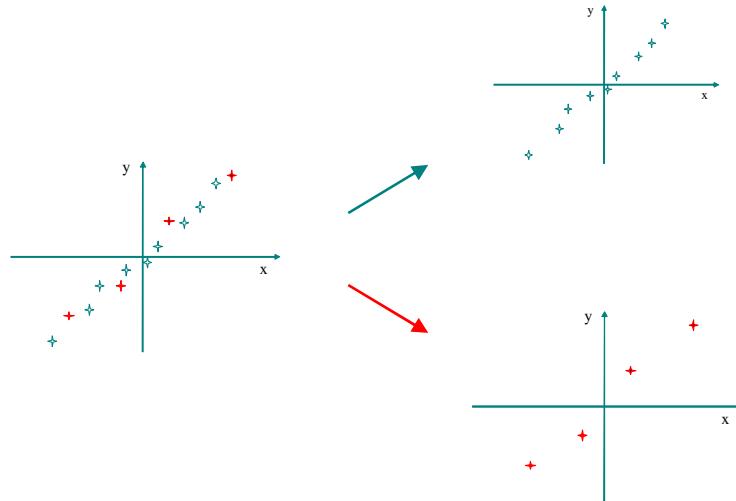
Crítica (acompanhamento) durante o treinamento !

## 6.3 – Overtraining (overfitting, sobre-treinamento)

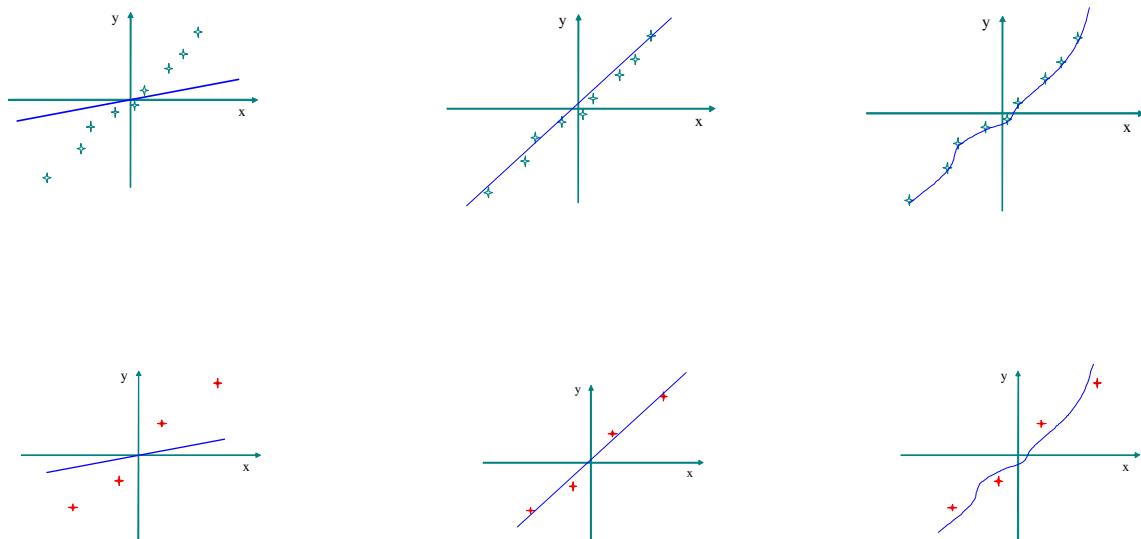


**Conjunto dos pares entrada saída >>>**

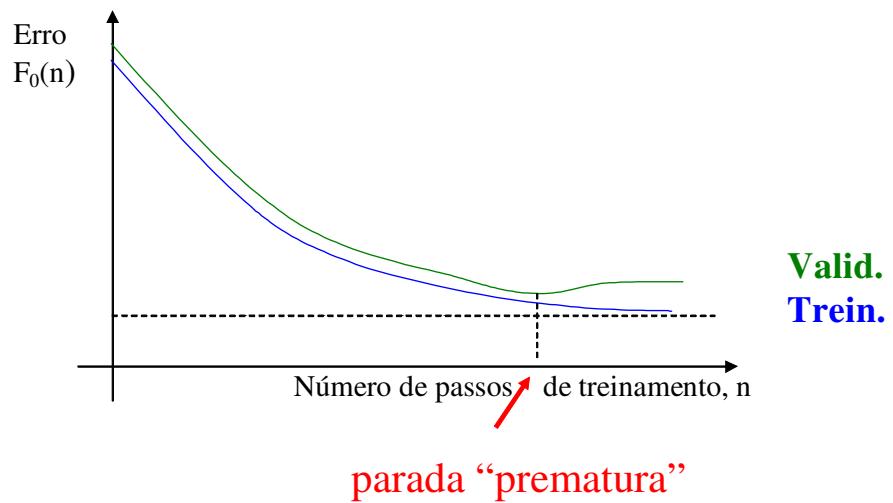
<b>Conjuntos de</b>	<b>Treinamento</b>	<b>60%</b>
	<b>Validação</b>	<b>20%</b>
	<b>(Teste</b>	<b>20%)</b>

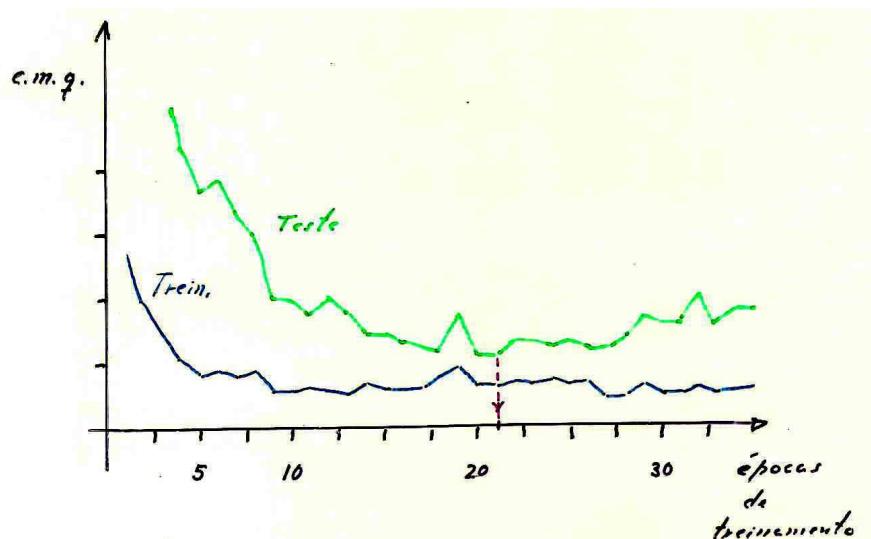


## Evolução dos erros ao longo do treinamento nos conjuntos de treinamento e de teste



## Controle do overtraining





“Save the Best”       $\underline{\epsilon}_{\text{teste}}^*$        $\underline{w}^*$

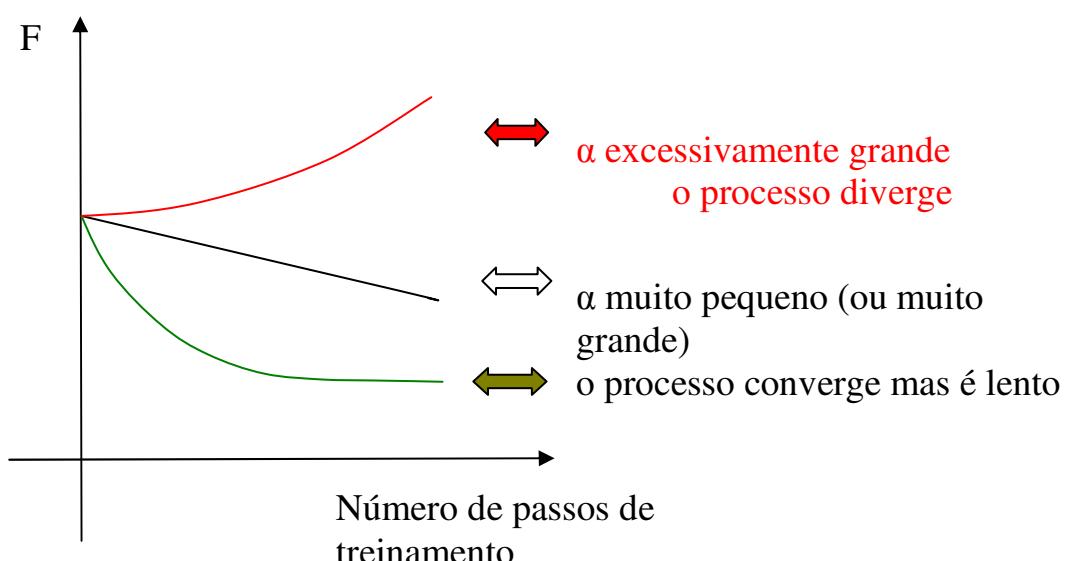
se para  $\underline{w} \neq \underline{w}^*$      $\epsilon_{\text{teste}}^* < \epsilon_{\text{teste}}$

faça     $\underline{w}^* = \underline{w}$     e     $\epsilon_{\text{teste}}^* = \epsilon_{\text{teste}}$

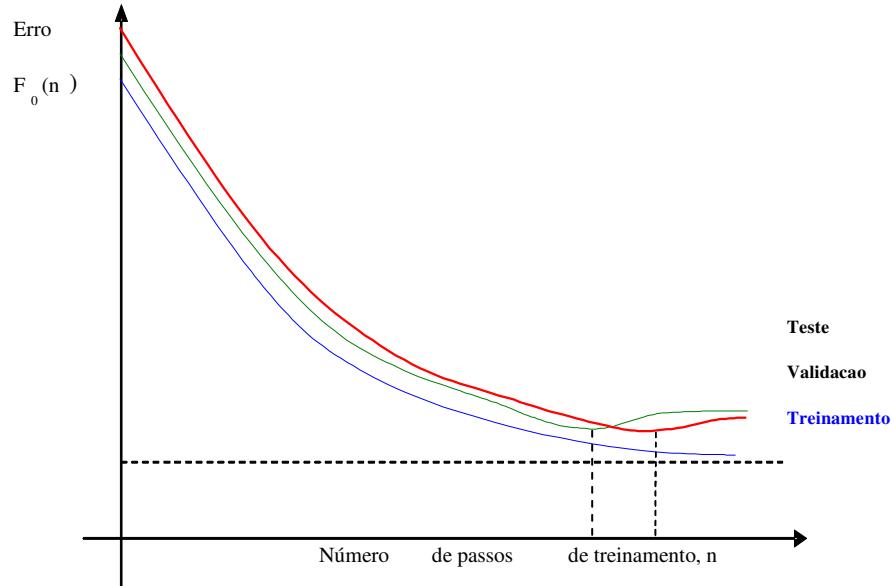
## 6.4 – Crítica durante o treinamento

Acompanhamento da evolução do erro nos conjuntos de treinamento, validação e teste durante o processo de treinamento

**no início do treinamento: avaliação de  $\alpha$**

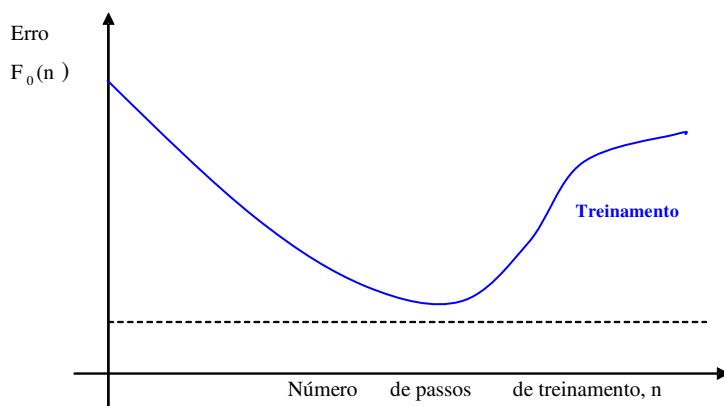


**durante o treinamento:**  
**controle do overtraining,**  
**parada prematura**



**Parada “prematura”:** duas soluções

**durante o treinamento:**  
**controle de possíveis divergências**



**“Divergência tardia”**

## Que tipo(s) de erro(s) acompanhar ?

**Saídas contínuas – Erro eficaz (erms) ou  
erro médio quadrático (emq)**

(erro na variável medida) versus (erro matemático)

$$erms = \sqrt{emq}$$

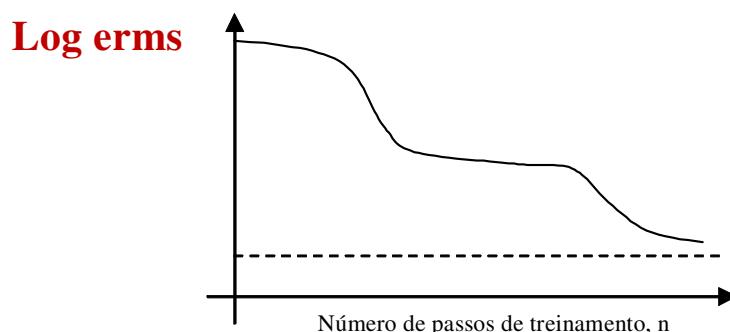
**Obs: se na normalização**  $y_i = \frac{1}{\sigma_{Y_i}} (Y_i - \mu_{Y_i})$

então o erro eficaz na saída real, não escalada, é:

$$erms_{Y_i} = \sigma_{Y_i} \ erms_{y_i}$$

## Escalas

Usualmente o erro médio quadrático (emq) e o erro eficaz (erms) variam por décadas - usar escala log



## Saídas Lógicas:

### Erms versus Erro de Classificação

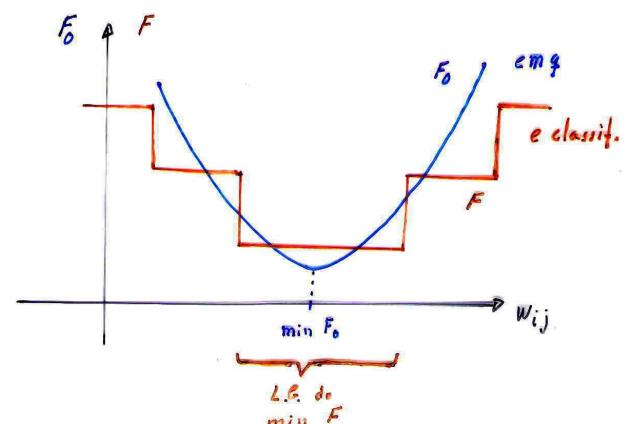
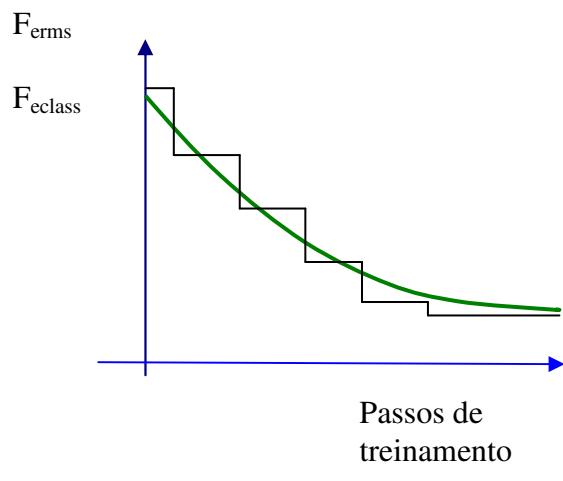
$$\begin{aligned}
 F_{\text{classificação}} &= \frac{1}{4} E_P [y_i - \text{sign}(\tilde{y}_i)]^2 \\
 &= \frac{1}{4P} \sum_{i=1}^P [y_i - \text{sign}(\tilde{y}_i)]^2
 \end{aligned}$$

- erro percentual eficaz na classificação

### No acompanhamento do erro de saídas lógicas

**Plotar os dois erros, log erms e erro de classificação !**

usar escala log



## 6.5 - Validação Cruzada

baixa estatística

Caso extremo: leave one out

Conjunto dos Pares entrada saída >>>

Conjunto A	20%
Conjunto B	20%
Conjunto C	20%
Conjunto D	20%
Conjunto E	20%

Composição dos Conjuntos:

Treinamento 60%	Validação 20%	Teste 20%
<b>C+D+E *</b>	<b>B</b>	<b>A</b>
<b>B+D+E</b>	<b>C</b>	<b>A</b>
<b>B+C+E</b>	<b>D</b>	<b>A</b>
<b>B+C+D</b>	<b>E</b>	<b>A</b>
<b>C+D+E *</b>	<b>A</b>	<b>B</b>
<b>A+D+E</b>	<b>C</b>	<b>B</b>
...	...	...
<b>A+B+D</b>	<b>C</b>	<b>E</b>
<b>A+B+C</b>	<b>D</b>	<b>E</b>

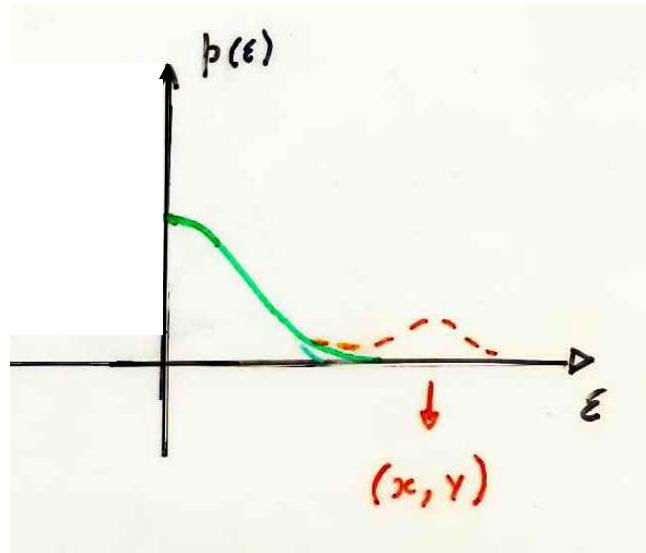
Total: 20 casos (\* 10 treinamentos a realizar)

Verificar média e dispersão do erro nos **conjunto de teste**.

## 6.6 Crítica pós-treinamento - histograma dos erros

$$(\underline{x}, \underline{y}) \rightarrow \underline{\tilde{y}} \rightarrow \varepsilon = |\underline{y} - \underline{\tilde{y}}|$$

$$\varepsilon_k > 3\sigma_\varepsilon \longrightarrow \text{Provável anomalia}$$



**Examinar conjuntos de treinamento, teste e validação**

**Anomalias possíveis:**

**Intrusos,**

**Regiões de baixa população**

**Mapeamento localmente complexos**

## Correção de anomalias: ver processos pós treinamento

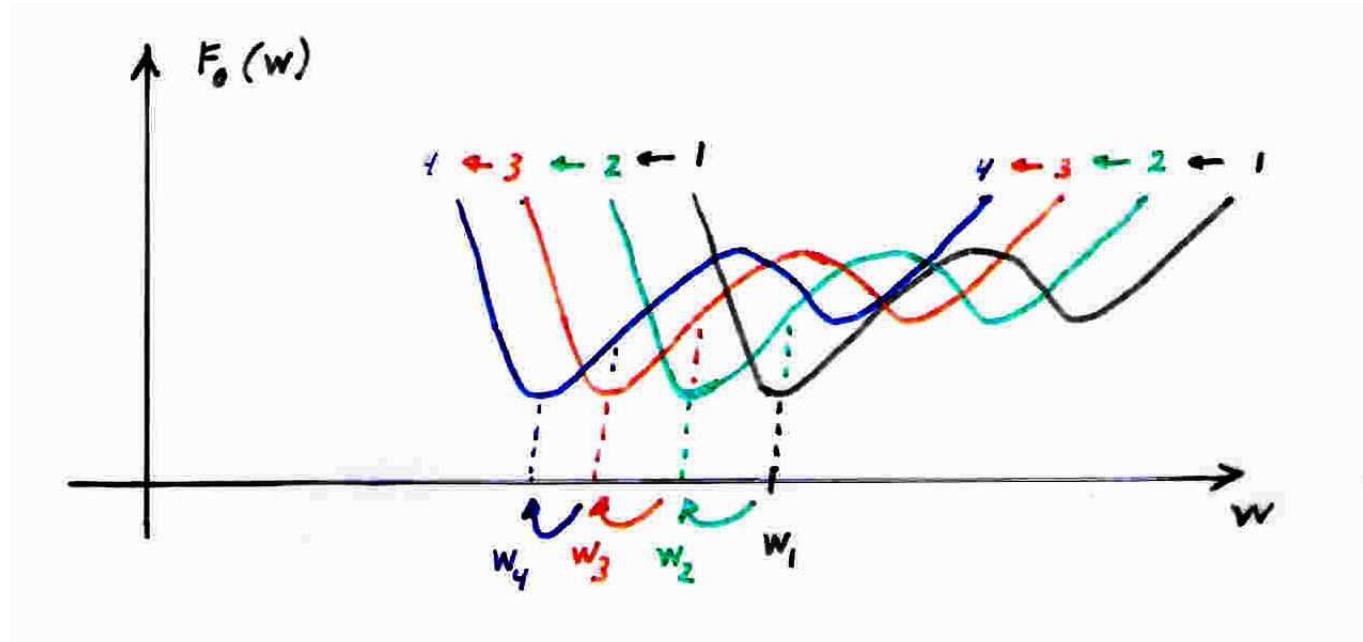
**Intrusos** - eliminar

**Regiões de baixa população** - replicar pares da região

**Mapeamento localmente complexos** - acrescentar neurônios com atuação na região (neurônios RBF ou tgh com  $\underline{w} \sim \underline{x}_{\text{crítico}}$ )

## 6.7 – Treinamento dinâmico, adaptativo

Sistemas variantes no tempo



### **Variações lentas nos pares entrada-saída (no mapeamento)**

**a rede acompanha, “aprende” o novo mapeamento e “esquece”os pares antigos (se  $\alpha > 0$  )**

### **Variações bruscas nos pares entrada –saída (no mapeamento)**

**a rede pode não aprender o novo mapeamento, pode ficar presa em um mínimo local, etc. Mais seguro refazer o treinamento.**