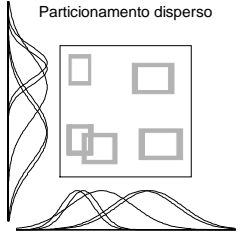
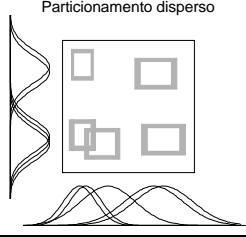


Errata

Identificação Neuro-Difusa: Aspectos de Interpretabilidade

Rui Pedro Pinto de Carvalho e Paiva

<i>pp (lin)</i>	<i>Onde se lê...</i>	<i>...deve ler-se...</i>
xxii (lin 32)	[em falta]	X_{max} (ou U_{max}) supremo do universo de discurso X_{min} (ou U_{min}) ínfimo do universo de discurso
xxiv (lin 22)	[em falta]	na_r número de entradas que constituem o antecedente da regra r
1 (lin 4 e 12)	<i>Gemotrie und Ergahrung</i>	<i>Geometrie und Erfahrung</i>
1 (lin 18)	a nível de capacidade de representação.	a nível de capacidade de representação e possibilidade de interpretação linguística.
25 (eq 2.19)	[...] $\hat{y}(k)$ [...]	[...] $\hat{y}(t)$ [...]
55 (lin 5)	e saídas efectivas, \hat{y}_j , da rede.	e saídas efectivas, \hat{y}_j , da rede. Define-se como saída de uma rede a activação de um dos neurónios da camada de saída.
55,56,60 (fig 4.1, eq 4.1 - 4.4)	F	\mathcal{F}
83 (lin 2)	, i.e., entradas, funções de pertinência, regras condicionais, conectivas difusas e desfuzificação.	, i.e., entradas, funções de pertinência, regras condicionais e conectivas difusas. No contexto presente, a rede não comporta uma camada de desfuzificação, uma vez que, neste ponto, a sua finalidade consiste na aprendizagem da estrutura. Somente na aprendizagem de parâmetros (Secção 5.3.) a rede incluirá uma camada de desfuzificação.
89 (fig 5.6)		
90 (lin 3)	, funções de pertinência bastante similares.	, funções de pertinência bastante similares. Além do mais, para cada variável, o número de funções de pertinência é igual ao número de partições definidas.
92 (lin 39)	modelos do tipo Takagi-Sugeno.	modelos do tipo Takagi-Sugeno de ordem 1.
93 (lin 1)	consequentes do tipo Takagi-Sugeno	consequentes do tipo Takagi-Sugeno de ordem 1
96 (lin 17)	\mathcal{E}^{up} especifica um limiar para o potencial acima do qual	\mathcal{E}^{up} especifica um limiar para o potencial, com base no mesmo para o primeiro grupo, acima do qual
99 (lin 15)	Ainda em relação à questão [...] Comparativamente à aprendizagem	Ainda em relação à questão da eficiência computacional, algoritmos iterativos do tipo <i>k-means clustering</i> [Moody e Darken, 1989], tornam-se particularmente interessantes no caso da sua aplicação ser efectuada no espaço multidimensional de entrada-saída. Nesse caso, em cada iteração há que procurar o centro mais próximo da nova amostra (definida em \Re^{m+n}), pelo que a complexidade computacional se torna de ordem $O(gNI)$. No entanto, são colocados alguns problemas relativamente à inicialização, bem como à robustez

		<p>bem como à robustez ao ruído.</p> <p>De notar que a análise efectuada é puramente qualitativa, sendo importante aferir o custo de alguns factores, tal como o peso computacional de cada iteração. Comparativamente à aprendizagem</p>
109 (lin 9)	activação dos neurónios nesta camada,	activação dos neurónios na quarta camada,
110 (lin 16)	verifica-se igualmente no caso de consequentes difusos ⁶⁴ .	verifica-se igualmente no caso de consequentes do tipo Takagi-Sugeno ⁶⁴ .
110 (lin 28)	Tal como no ponto anterior	Tal como se referiu no ponto anterior
111 (lin 34)	$d_o^{(p)}$	$y_o^{(p)}$
112 (eq 5.51)	$\frac{\partial E_o^{(p)}}{\partial \sigma_{osL}} = [...]$	$\frac{\partial E_o^{(p)}}{\partial \sigma_{os}} = [...]$
114 (lin 1)	a definição de funções Gaussianas é efectuada sem	a definição de funções Gaussianas é efectuada, na versão original, sem
116 (eq 5.71)	$\delta_r^{(p3)} = -\delta_o^{(p4)} \cdot \frac{\partial a_o^{(p4)}}{\partial a_r^{(p3)}} = [...]$	$\delta_r^{(p3)} = -\delta_o^{(p4)} \cdot \frac{\partial a_o^{(p4)}}{\partial a_r^{(p3)}} = [...]$
117 (eq 5.74)	$\Phi = \begin{bmatrix} \frac{a_1^{(13)}}{\sum_{r=1}^g a_r^{(13)}} X^{(1)} & \frac{a_1^{(23)}}{\sum_{r=1}^g a_r^{(23)}} X^{(2)} & \frac{a_1^{(N3)}}{\sum_{r=1}^g a_r^{(N3)}} X^{(N)} \\ \frac{a_2^{(13)}}{\sum_{r=1}^g a_r^{(13)}} X^{(1)} & \frac{a_2^{(23)}}{\sum_{r=1}^g a_r^{(23)}} X^{(2)} & \frac{a_2^{(N3)}}{\sum_{r=1}^g a_r^{(N3)}} X^{(N)} \\ \vdots & \vdots & \dots & \vdots \\ \frac{a_{g1}^{(13)}}{\sum_{r=1}^g a_r^{(13)}} X^{(1)} & \frac{a_{g1}^{(23)}}{\sum_{r=1}^g a_r^{(23)}} X^{(2)} & \frac{a_{g1}^{(N3)}}{\sum_{r=1}^g a_r^{(N3)}} X^{(N)} \end{bmatrix}$	$\Phi = \begin{bmatrix} \frac{a_1^{(13)}}{\sum_{r=1}^g a_r^{(13)}} X^{(1)} & \frac{a_1^{(23)}}{\sum_{r=1}^g a_r^{(23)}} X^{(2)} & \frac{a_1^{(N3)}}{\sum_{r=1}^g a_r^{(N3)}} X^{(N)} \\ \frac{a_2^{(13)}}{\sum_{r=1}^g a_r^{(13)}} X^{(1)} & \frac{a_2^{(23)}}{\sum_{r=1}^g a_r^{(23)}} X^{(2)} & \frac{a_2^{(N3)}}{\sum_{r=1}^g a_r^{(N3)}} X^{(N)} \\ \vdots & \vdots & \dots & \vdots \\ \frac{a_g^{(13)}}{\sum_{r=1}^g a_r^{(13)}} X^{(1)} & \frac{a_i^{(23)}}{\sum_{r=1}^g a_r^{(23)}} X^{(2)} & \frac{a_g^{(N3)}}{\sum_{r=1}^g a_r^{(N3)}} X^{(N)} \end{bmatrix}$
122 (lin 2)	<i>k-nearest neighbours</i>	<i>k-means clustering</i>
126 (lin 33)	<p>do número de funções de pertença definidas para a variável em causa.</p> <p>O desenvolvimento de modelos</p>	<p>do número de funções de pertença definidas para a variável em causa.</p> <p>No caso da distância mínima entre funções não se verificar, os centros respectivos são alterados da forma que se segue (5.85):</p> $c_{kR}^{new} = \frac{c_{kR} + c_{iL}}{2} - \frac{\alpha(U_{\max} - U_{\min})}{2} \quad (5.85)$ $c_{iL}^{new} = \frac{c_{kR} + c_{iL}}{2} + \frac{\alpha(U_{\max} - U_{\min})}{2}$ <p>Nesta situação, os novos centros terão por referência a média dos centros direito e esquerdo originais de cada função, a partir da qual os seus valores são alterados de acordo com a distância mínima definida.</p> <p>O desenvolvimento de modelos</p>
140 (lin 23)	treino restrungido,	treino não restrungido,

Legenda: *pp* - página *lin* - linha *eq* - equação *fig* - figura