

PSI2672 – Práticas em Reconhecimento de Padrões, Modelagem e Neurocomputação

Prof. Emílio del Moraz Hernandez

Departamento de Engenharia de Sistemas Eletrônicos

Daniel Seinderberger Torres

Daniel Silva Ferreira Bruno

Douglas Martins Veronez

Rodrigo Gama

2011

Sumário

- Objetivo
- Língua Eletrônica
- Natureza dos Sinais
- Sistema de Aquisição
- Gerador de dados simétricos
- Estrutura da RNA
- Metodologia de Treino
- Determinação do número de nós
- Resultados
- Testes
- Comentários e Conclusões
- Agradecimentos
- Bibliografia

Objetivo

- Uma língua eletrônica que possa determinar propriedades do leite.
- Processar Sinais elétricos correspondentes às características do leite.
- Estimar as concentrações percentuais destas características

Língua Eletrônica

- Línguas–eletrônicas são sistemas multisensores
- Analisa características de substâncias usando sensores não específicos.
- Sensores possuem respostas diferentes dependendo da frequência que os excita.
 - Em uma frequência f_1 o sensor 1 pode ser extremamente seletivo para gordura
 - Em uma frequência f_2 ele pode não apresentar seletividade nenhuma

Natureza dos Sinais

- Sinais elétricos capturados por sensores em contato direto com o líquido;
- Sinais proporcionais às concentrações percentuais;



Divisão de Tarefas

- ▶ Daniel Torres
 - Criação da matriz de concentrações
- ▶ Daniel Bruno
 - Planejamento de da Matriz de Mistura
- ▶ Douglas
 - Implementação do gerador de dados
- ▶ Rodrigo
 - Implementação da Rede em Matlab

Gerador de dados Sintéticos

- Variação das concentrações [%] obtidas da literatura:
 1. Gordura
 2. Proteína
 3. Lactose
 4. pH

Tabela 2 - Médias e desvios-padrão (DP) das medidas descritivas de 257.540 amostras de leite, analisadas no período 1999-2001 pelo PARLPR

Table 2 - Means and standard deviation (SD) of the descriptive measurements of 257,540 milk samples, analysed between 1999-2001 by PARLPR

Características estudadas (%) <i>Studied characteristics</i>	Média <i>Means</i>	±	DP <i>SD</i>
Concentração de gordura <i>Fat concentration</i>	3,69	±	0,62
Concentração de proteína <i>Protein concentration</i>	3,24	±	0,24
Concentração de lactose <i>Lactose concentration</i>	4,55	±	0,19
Concentração de sólidos não gordurosos <i>Solids not fat concentration</i>	8,62	±	0,38
Concentração de sólidos totais <i>Total solids concentration</i>	12,32	±	0,79

Gerador de dados Sintéticos

- ▶ Valores gerados randomicamente
- ▶ Matriz 150x4 de concentrações percentuais
- ▶ Aplica-se não linearidades nos valores
- ▶ Passa por 5 Matrizes de Mistura
- ▶ Cada matriz representa uma Frequência

Gerador de Dados Sintéticos

M1	0.6000	0.2000	0.1500	0.0500
	0.1000	0.7500	0.3000	0.0500
	0.2000	0.2000	0.8000	0
	0	0.0400	0.0600	0.9000

M2	0.9000	0.0500	0.0500	0
	0.0500	0.6000	0.0500	0.3000
	0.3000	0.2500	0.4000	0.0500
	0.1000	0	0.1000	0.8000

M3	0.0500	0.2000	0.2000	0.1000
	0.1000	0.6000	0.1000	0.2000
	0.0300	0.0200	0.9000	0.0500
	0.1000	0.1000	0.1000	0.7000


M4	0.0600	0.3000	0	0.1000
	0.1000	0.9000	0	0
	0.2000	0.2000	0.4000	0.2000
	0.3000	0.1000	0.2000	0.4000

M5	0.0400	0.3000	0.2000	0.1000
	0.1000	0.6000	0.1000	0.2000
	0.2000	0.2000	0.6000	0
	0	0.1000	0.2000	0.7000

Matrizes de Mistura para as 5 frequências de medida

Estrutura da RNA

- ▶ 20 entradas
- ▶ 4 saídas
- ▶ 22 neurônios
- ▶ 1 camada escondida




Metodologia de Treino


- Geradas 150 amostras;
- 100 amostras na RNA para treino, com 20 dados de entrada. 50 amostras para teste.
- RNA 20-10-4;
- Função da camada escondida: tanh
- Função do output: linear

Determinação do Número de Nós

- Variação do número de nós de 6 a 100;

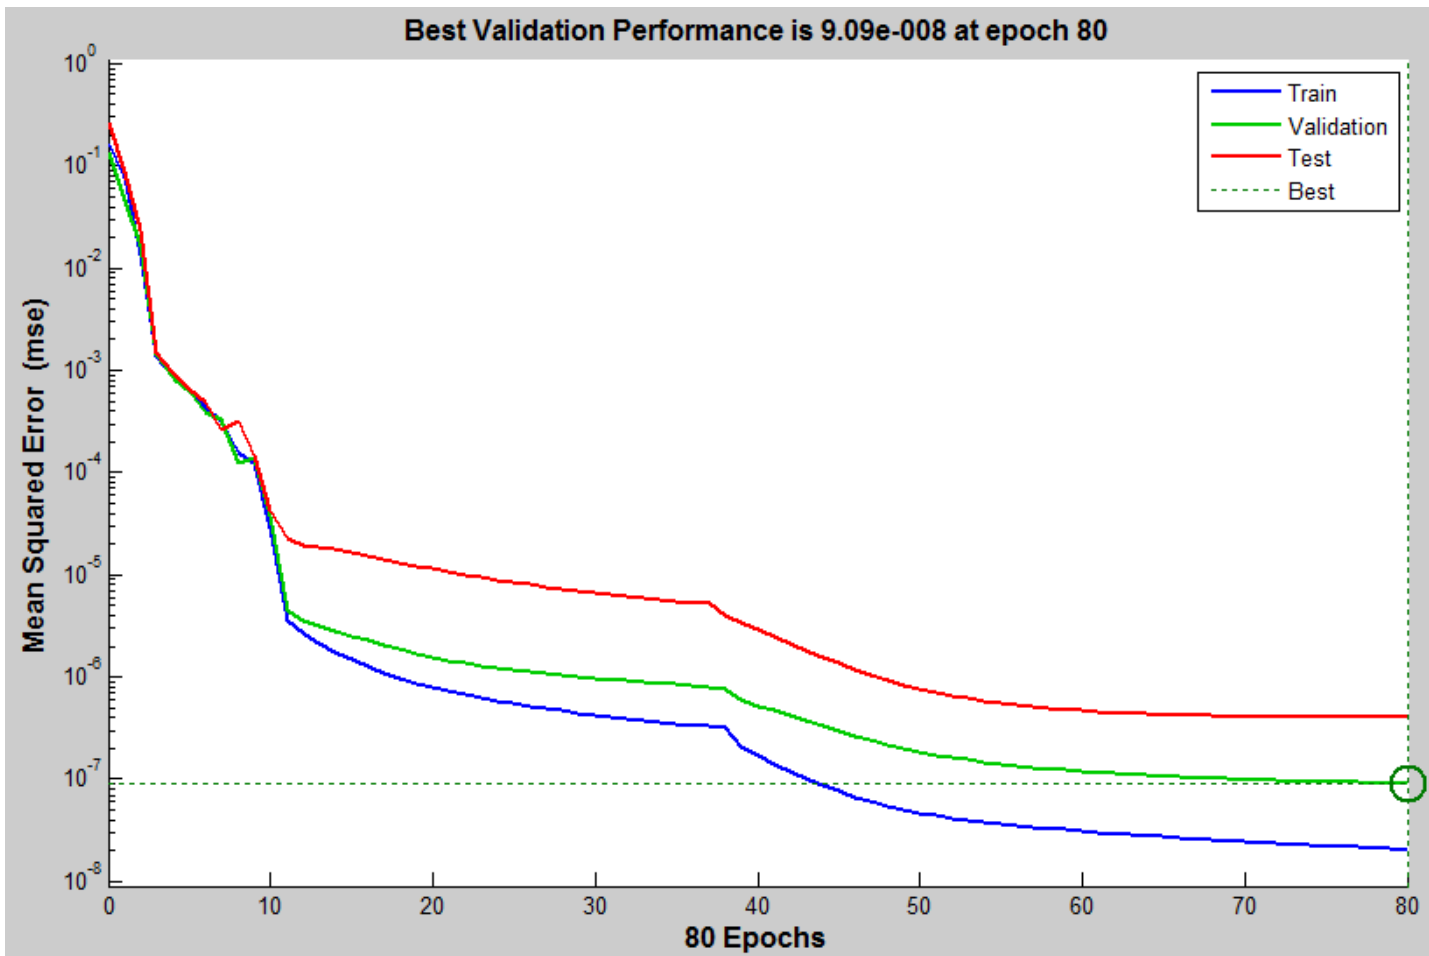


Resultados




Progress			
Epoch:	0	80 iterations	1000
Time:		0:00:09	
Performance:	0.164	2.05e-08	0.00
Gradient:	0.634	9.66e-06	1.00e-05
Mu:	0.00100	1.00e-05	1.00e+10
Validation Checks:	0	0	6


Resultados



Resultados – Treino



Resultados - Teste



errqm = 1.0e-006 * [0.2843 0.0383 0.0184 0.2710]

Comentários e Conclusões

- ▶ A utilização de RNA's para processar dados de Línguas Eletrônicas gera bons resultados
- ▶ Características com valores pequenos e faixas estreitas são mais difíceis de serem tratadas
- ▶ *Early* stopping evita sobre aprendizado e traz bons resultados mesmos para redes subdimensionadas.

Agradecimentos

- Professor Emílio;
- Doutor Itamar Magno Barbosa;
- Mathworks;
- Autor do software MBP;
- A todos que de alguma forma ajudaram e ainda estão ajudando no andamento desse trabalho;

Bibliografia

- ▶ CASSOLI, Laerte Dagher; MACHADO, Paulo Fernando; COLDEBELLA, Arlei. Métodos de conservação de amostras de leite para determinação da contagem bacteriana total por citometria de fluxo. Revista Brasileira de Zootecnia, v.39, n.2, p. 434 -439, 2010.
- ▶ BARBOSA, Itamar Magno. Estudo das Dispersões Metrológicas em Redes Neurais Artificiais do tipo Multilayer Perceptrons Através da Aplicação em Curvas de Calibração. Escola Politécnica da USP. Tese de Doutorado. São Paulo, 2010.