

SISTEMA NEURO-DIFUSO PARA DIAGNÓSTICO DE MOTORES ATRAVÉS DA ANÁLISE DE AMOSTRAS DE ÓLEO

GIZELLE K. VIANNA, ANTONIO C. G. THOMÉ

*Área de Ensino e Pesquisa, NCE/IM, Universidade Federal do Rio de Janeiro
Rio de Janeiro, RJ, BRASIL*

E-mails: kupac@novell.nce.ufrj.br, thome@novell.nce.ufrj.br

Resumo Este artigo descreve um sistema híbrido neuro-difuso utilizado no diagnóstico de motores de automóveis, através da análise de amostras de óleo. Realizou-se uma análise de relevância para selecionar as variáveis mais significativas, dentre aquelas disponíveis, para a classificação das amostras. Esta análise está descrita de forma detalhada neste artigo. Foram implementados 4 diferentes sistemas: um sistema neural puro, e três diferentes sistemas neuro-difusos. Apresenta-se também a descrição detalhada do sistema neural e dos sistemas nebulosos, bem como o desempenho obtido por cada um deles.

Abstract The present paper describes a neuro-fuzzy hybrid system applied in the diagnosis of automobile engines, based on the analysis of oil samples. A relevance analysis has been done to select the most significant variables among the available ones, in order to classify the samples. Such relevance analysis is described in details along the present paper. Four different systems have been implemented: one pure neural system, and three different neuro-fuzzy systems. A detailed description of the neural and fuzzy systems is also presented, as well as the performance obtained by each one of them.

Keywords Artificial intelligence, Automatic recognition, Classification, Fuzzy hybrid systems, Fuzzy modeling, Membership functions, Neural networks.

1 Introdução

O exame do óleo do motor de um automóvel pode ser comparado ao exame de sangue em um ser humano. Se amostras de óleo forem periodicamente retiradas de um motor para análises químicas, problemas mecânicos podem ser previstos e tratados com antecedência. Em empresas que possuam grandes frotas de veículos, o acompanhamento rotineiro do estado óleo dos motores pode gerar uma economia significativa, ao reduzir ou evitar as panes mecânicas e também ao aumentar o período entre trocas de óleo.

Trata-se, portanto, de um serviço preventivo, que compreende as seguintes fases:

- 1) Coleta periódica de amostras de óleo;
- 2) Análise química das amostras;
- 3) Identificação das amostras cujo exame laboratorial revele indícios de problemas quanto a desgaste, combustão ou contaminação;
- 4) Diagnóstico do problema;
- 5) Emissão do laudo técnico.

O objetivo de um sistema automatizado neste processo é agilizar a fase de identificação das amostras, separando-as em dois conjuntos: o dos motores em bom estado e o dos que devem passar por um exame mais detalhado, a ser feito por uma equipe especializada. Esse é, na prática, um dos gargalos do processo, uma vez que a maioria das amostras de óleo não apresenta qualquer tipo de problema.

Neste artigo descreve-se uma investigação onde se aborda o problema através de um modelo compu-

tacional híbrido, associando as tecnologias de redes neurais e da lógica nebulosa (Cox, 1998 e Haykin, 1999). Um conjunto de amostras, contendo os resultados obtidos após a conclusão da fase 2, foi utilizado para o treinamento, validação e testes do sistema. A seção 2 contém a descrição das amostras e, na seção 3, a análise de relevância realizada sobre as variáveis, a fim de selecionar apenas as mais significativas para a classificação. Na seção 4, encontra-se a definição dos critérios de seleção de variáveis utilizados. Na seção 5, descreve-se o modelo neural desenvolvido e na seção 6, o modelo híbrido final.

2 Amostras de Dados

O conjunto de dados disponibilizado para esta investigação perfaz um total de 725 amostras, cada uma contendo 27 resultados de análises químicas do óleo. Cada uma das análises químicas será chamada de variável, e será representada pelo símbolo V_i .

Cada amostra recebe 3 diferentes diagnósticos: um relativo ao desgaste, outro à combustão e o último à contaminação. Os diagnósticos serão identificados, a partir de agora, pelos símbolos D_1 , D_2 e D_3 , respectivamente. No sistema implementado, cada diagnóstico D_i pode receber um dentre dois valores: 0 ou 1. Um diagnóstico cujo valor é 0, significa uma amostra isenta de problemas, enquanto um diagnóstico igual a 1 significa que a amostra é indicativa de problemas no motor correspondente.

No conjunto de dados históricos recebido da empresa que suporta esta pesquisa, a estatística dos

diagnósticos apresentou a distribuição descrita pela *Tabela 1*.

Pode-se observar que o percentual de diagnósticos iguais a 1 é bem menor do que o outro, o que torna o conjunto muito desigual. Essa distribuição desigual dificulta, significativamente, o processo de treinamento e validação do sistema. A fim de minimizar o problema, investigou-se a hipótese de gerar, artificialmente, um conjunto adicional de amostras, como será descrito mais adiante.

Tabela 1. Distribuição dos diagnósticos no conjunto histórico.

D_i	Total de $D_i = 1$	% de $D_i = 1$	Total de $D_i = 0$	% de $D_i = 0$
D_1	83	12,93%	642	87,07%
D_2	18	2,55%	707	97,45%
D_3	30	4,14%	695	95,86%

Verificou-se também, que a ordem de grandeza de cada variável é muito heterogênea. Além disso, ao observar a *tabela 2*, percebe-se que a diferença entre os valores máximo e mínimo de cada coluna é bastante significativa. A fim de homogeneizar o intervalo de valores possíveis dentro do conjunto de variáveis, estas foram normalizadas através de um processo de normalização linear. Utilizou-se, para tal, a fórmula 1 abaixo, que atribui um valor linearmente distribuído entre 0 e 1, a cada variável:

$$x_{new} = \frac{x_{old} - x_{min}}{x_{max} - x_{min}} \quad (1)$$

A normalização foi efetuada antes do processo de análise da relevância das variáveis. Somente após essa fase, o conjunto de dados foi disponibilizado para o treinamento das redes neurais.

A *Tabela 2* mostra informações adicionais acerca da distribuição original das variáveis.

3 Análise de Relevância

A análise das variáveis foi realizada separadamente, para cada um dos diagnósticos existentes. Assim, na descrição do procedimento que se segue, deve-se observar que cada etapa foi realizada analisando-se apenas um dos diagnósticos. O processo como um todo foi repetido três vezes, uma vez para cada diagnóstico.

O primeiro passo foi separar o conjunto de amostras em dois grupos: um contendo as amostras que apresentassem diagnósticos iguais a 1, e outro aquelas com diagnóstico iguais a 0. Os grupos serão identificados como G_1 e G_0 , respectivamente.

Analisou-se a seguir, a distribuição de cada variável, em cada um dos grupos 1e 0 (Wonnacott, 1985 e Spigel, 1978). Foram gerados 27 gráficos, que exibem a distribuição dos valores de cada variável V_i

dentro de cada grupo G_i . Dois desses gráficos de distribuição estão mostrados nas figuras 1 e 2. A curva de distribuição referente a G_1 está exibida em linha cheia, e a referente a G_0 , em linha pontilhada.

A seguir, realizou-se uma análise dos gráficos, com o objetivo de verificar a capacidade de discriminação de cada variável, quanto aos diagnósticos 0 e 1.

4 Critérios de Seleção

As figuras 1 e 2 mostram as curvas gaussianas que representam a distribuição das variáveis V_1 e V_2 em relação ao diagnóstico 1 (linha contínua) e ao diagnóstico 0 (linha pontilhada). Observa-se que, na figura 1, a interseção entre as curvas é relativamente pequena, principalmente quando comparada com a da figura 2, que é bem maior. Uma maior separação das curvas sugere um poder maior de discriminação. As variáveis escolhidas foram aquelas que apresentaram as menores interseções entre as curvas de distribuição.

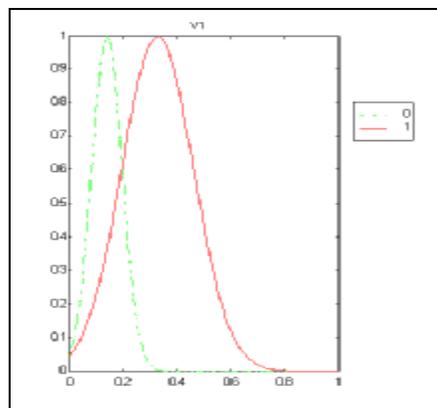


Figura 1. Distribuição da variável V_1 .

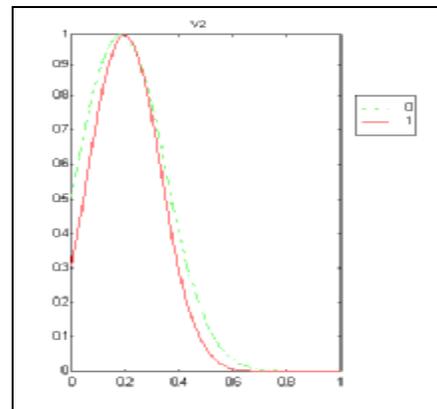


Figura 2. Distribuição da variável V_2 .

Em função da análise descrita anteriormente, foram pré-selecionadas, para o treinamento das redes neurais, as variáveis listadas na *tabela 3*.

Após a pré-seleção, decidiu-se verificar também a correlação cruzada entre as variáveis selecionadas e comparar as variâncias de cada uma delas.

A análise dessas correlações visa identificar variáveis que apresentem pouca informação adicional à apresentada pelas outras. Para tal, deve-se identificar, dentro do conjunto de variáveis pré-selecionadas, duplas de variáveis com alta correlação. A variável selecionada é aquela que apresenta a maior variância, podendo-se descartar a outra, sem perda sensível de informação. Ao final desta análise, chegou-se ao conjunto de variáveis, mais reduzido, listado na *tabela 4*.

Tabela 2. Distribuição das variáveis em C₁.

COLUN A	MÁX.	MÍN.	m	s
V ₁	542,00	11,00	97,24	48,82
V ₂	31,00	0,00	3,63	3,13
V ₃	127,00	0,00	11,58	9,18
V ₄	74,00	1,00	6,88	6,50
V ₅	27,00	0,00	4,18	2,11
V ₆	43,00	1,00	8,50	4,05
V ₇	43,00	1,00	8,50	4,05
V ₈	5,00	0,00	0,75	0,88
V ₉	45,00	4,00	10,31	3,99
V ₁₀	64,00	0,00	0,23	2,51
V ₁₁	400,00	1,00	168,22	108,76
V ₁₂	1037,00	15,00	471,39	300,39
V ₁₃	3828,00	452,00	1676,80	704,07
V ₁₄	30,00	0,00	0,20	2,16
V ₁₅	1429,00	268,00	894,34	225,80
V ₁₆	2004,00	340,00	1134,50	292,94
V ₁₇	63,00	0,00	6,84	5,41
V ₁₈	1,00	0,00	0,00	0,04
V ₁₉	1,00	0,00	0,00	0,04
V ₂₀	24,00	0,00	4,49	3,76
V ₂₁	0,38	0,01	0,08	0,04
V ₂₂	0,61	0,01	0,10	0,05
V ₂₃	0,43	0,01	0,15	0,05
V ₂₄	2,50	0,00	0,61	0,31
V ₂₅	2,00	0,10	0,11	0,10
V ₂₆	0,23	0,08	0,08	0,01
V ₂₇	10,00	2,00	2,07	0,62

5 O Modelo Neural

5.1 Primeiros Experimentos

O conjunto de amostras foi dividido em três partes: a primeira contendo as amostras utilizadas para o treinamento das redes, a segunda as amostras utilizadas para a validação, durante o treinamento, e a última para os testes de desempenho.

Experimentos iniciais mostraram que as redes neurais não obtinham um desempenho satisfatório em seus treinamentos. O motivo para tal comportamento foi identificado como consequência da pouca quantidade de exemplos, cujos diagnósticos fossem iguais a 1. A fim de contornar essa limitação, foram gerados,

aleatoriamente, alguns exemplos de diagnóstico 1, mantendo-se as características estatísticas, momentos de 1^a e 2^a ordem, do conjunto de amostras disponível.

A operação não alterou as distribuições de cada variável e, como consequência, as variáveis selecionadas anteriormente continuaram válidas. A fórmula 2 abaixo, foi utilizada para a criação das amostras artificiais:

$$x_{new} = x_{ori} + rand \times v(x_{ori})$$

Onde:

x_{ori} é uma amostra pertencente ao conjunto original, (2)

x_{new} é a nova amostra

$v(x_{ori})$ é a variância do conjunto original de amostras

Tabela 3. Variáveis selecionadas através da análise da distribuição.

D ₁	D ₂	D ₃
Selecionadas	Selecionadas	Selecionadas
V ₁	V ₁	V ₁
V ₂	V ₂	V ₂
V ₃	V ₃	V ₃
V ₄	V ₄	V ₄
V ₅	V ₅	V ₅
V ₆	V ₆	V ₆
V ₉	V ₉	V ₉
V ₁₁	V ₁₄	V ₁₄
V ₁₂	V ₁₇	V ₁₇
V ₁₃	V ₂₁	V ₁₈
V ₁₇	V ₂₂	V ₂₅
V ₁₈	V ₂₃	V ₂₇
V ₂₃	V ₂₄	
V ₂₄	V ₂₇	
V ₂₇		

Tabela 4. Variáveis selecionadas através da análise da correlação e variância.

D ₁	D ₂	D ₃
Selecionadas	Selecionadas	Selecionadas
V ₁	V ₁	V ₁
V ₄	V ₄	V ₄
V ₁₂	V ₅	V ₅
V ₁₃	V ₁₄	V ₁₄
V ₁₈	V ₂₁	V ₁₈
V ₂₄	V ₂₄	V ₂₅
V ₂₇	V ₂₇	V ₂₇

Com a aplicação da *fórmula.2*, aumentou-se o número de exemplos para treinamento e validação, em cada diagnóstico. As quantidades iniciais e finais, obtidas após essa operação, estão descritas na tabela abaixo:

Tabela 5. Quantidades iniciais e finais de diagnósticos 1 utilizadas para o treinamento das redes. T=conjunto de treinamento e V=conjunto de validação.

D ₁	D ₂	D ₃
----------------	----------------	----------------

	Inicial	Final	Inicial	Final	Inicial	Final
T	41	123	9	153	15	135
V	17	121	4	131	6	127

5.2 Descrição do modelo neural

Para a abordagem do problema, foram utilizadas três redes neurais *feedforward*, treinadas pelo método do *Backpropagation*, uma para cada tipo de diagnóstico. Cada rede possui duas camadas de neurônios, porém o número de neurônios existentes em cada camada varia de acordo com o diagnóstico que está sendo realizado. Os parâmetros de treinamento foram os mesmos, para as três redes.

Nem todos as amostras disponíveis foram utilizadas no processo de treinamento, pois a diferença percentual entre diagnósticos iguais a 1 e iguais a 0 levaria novamente a um desempenho deficiente do sistema. A quantidade de amostras utilizadas em cada diagnóstico está descrita na tabela abaixo:

Tabela 6. Distribuição de diagnósticos dentro dos conjuntos de treinamento, validação e teste.

D _i	TREIN.		VAL.		TESTE		TOTAL	
	0	1	0	1	0	1	0	1
1	230	123	138	121	92	17	460	165
2	230	153	138	131	92	4	460	162
3	230	135	138	127	92	6	460	150

5.3 Resultados obtidos

Os testes de desempenho foram realizados separadamente para cada diagnóstico, *utilizando-se* o conjunto de teste descrito na *tabela 6*. Foram analisadas 182 arquiteturas de rede diferentes e, para cada uma delas, realizou-se 50 treinamentos. Para cada arquitetura, calculou-se a média dos desempenhos e as melhores arquiteturas foram então selecionadas.

O desempenho da melhor rede, para cada diagnóstico, está detalhado nas *tabelas 7 a 9*. Nessas tabelas, acertos correspondem a diagnósticos 1, ou 0, que foram classificados corretamente pela rede neural correspondente. Erros são diagnósticos 1 que foram classificados como 0 pela rede neural, ou diagnósticos 0 como 1.

Para cada modelo, foram definidos *threshold* (limites de corte) para cada diagnóstico. A escolha dos *thresholds* foi realizada com base na distribuição das saídas fornecidas pelas redes quando apresentadas aos conjuntos de validação de cada diagnóstico (*figuras 3 a 5*). Cada curva corresponde à distribuição das saídas geradas pela rede para os diagnósticos do tipo 0 e do tipo 1.

Através da análise das distribuições, definiu-se cada *threshold* como sendo um ponto interior à área de interseção entre as curvas de distribuição, que melhor selecionasse os conjuntos. Foram realizadas várias simulações para cada diagnóstico, de forma a

encontrar os melhores *thresholds*. As simulações ficaram sempre restritas ao conjunto de validação.

Para o primeiro diagnóstico (D_1), o experimento realizado obteve um desempenho global de 86,45% (tabela 7). A rede neural que obteve o melhor desempenho possui a configuração 7-7-3-1 e foi treinada em uma média de 430 ciclos.

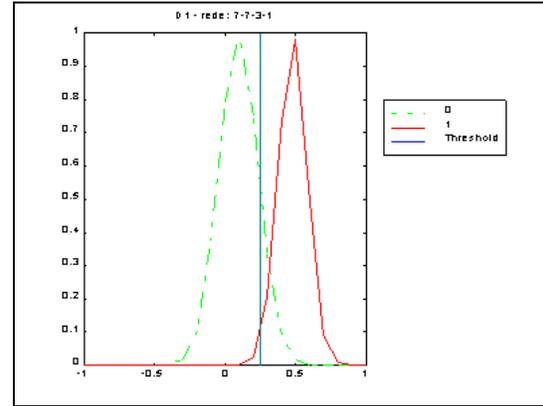


Figura 3. Curvas de distribuição das saídas geradas pela rede neural, no diagnóstico D_1 . A reta vertical indica a posição do threshold.

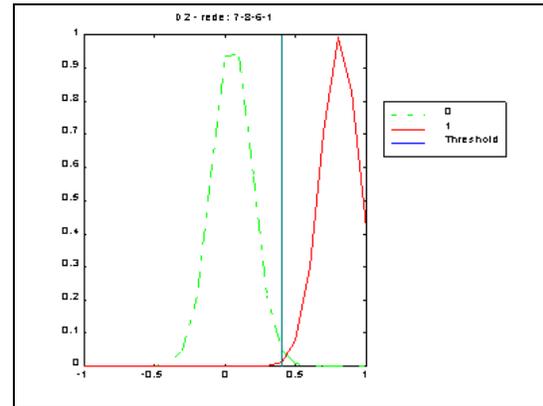


Figura 4. Curvas de distribuição das saídas geradas pela rede neural, no diagnóstico D_2 , com threshold indicado pela reta vertical.

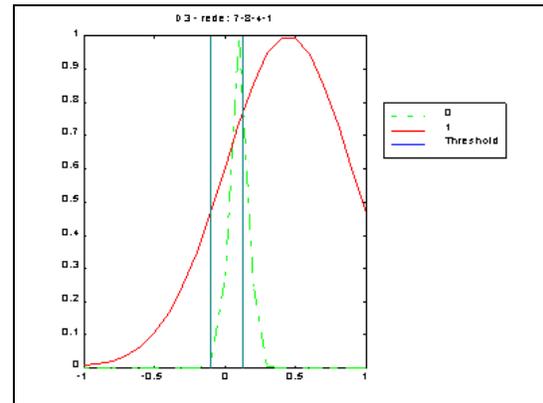


Figura 5. Curvas de distribuição das saídas geradas pela rede neural, no diagnóstico D_3 , com threshold indicado pela reta vertical.

O *threshold* utilizado foi 0,25 e para is elementos de processamento, utilizou-se uma função de propagação linear, em todas as camadas. Foram realizados também experimentos com a mesma rede, porém utilizando-se a função de propagação logarítmica. O desempenho foi significativamente inferior.

Para o segundo *diagnóstico*, o experimento realizado obteve um desempenho global de 96,94% (tabela 8). A rede neural que obteve o melhor desempenho possui a configuração 7-8-6-1, treinada em uma média de 300 ciclos. O *threshold* utilizado foi 0,4. Novamente o treinamento foi realizado utilizando-se uma função de ativação linear.

Tabela 7. Desempenho da rede responsável pela análise do diagnóstico 1.

TARGET	% ACERTOS	% ERROS	TOTAL
0	85,62%	14,38%	138
1	91,04%	8,96%	25

Tabela 8. Desempenho da rede responsável pela análise do diagnóstico 2.

TARGET	% ACERTOS	% ERROS	TOTAL
0	97,52%	2,48%	138
1	80,80%	19,20%	5

No terceiro *diagnóstico*, o experimento realizado obteve um desempenho global de 82,49% (tabela 9). A rede neural que obteve o melhor desempenho possui a configuração 7-8-4-1, com média de 240 ciclos de treinamento. O *threshold* utilizado foi o intervalo [-0,1; 0,13]. O treinamento também foi realizado utilizando-se uma função de ativação linear.

Tabela 9. Desempenho da rede responsável pela análise do diagnóstico 3.

TARGET	% ACERTOS	% ERROS	TOTAL
0	82,06%	17,94%	138
1	89,11%	10,89%	9

6 O Modelo Híbrido

6.1 Descrição do Módulo Nebuloso

Um módulo difuso foi posteriormente acoplado ao modelo neural descrito anteriormente, como forma de investigar a possibilidade de melhorar o desempenho do sistema.

O modelo difuso construído é bastante simples, e baseia-se nos resultados gerados pelas redes neurais. Para a construção do modelo difuso, fez-se uso apenas dos conjuntos de validação, conforme descrito na *tabela 6*.

Cada conjunto de validação foi apresentado à rede neural correspondente. As saídas geradas por cada rede, para cada amostra apresentada, foram agrupadas em dois subconjuntos: o primeiro contendo as saídas da rede quando os diagnósticos correspondentes eram iguais à 1, e o segundo para os diagnósticos iguais à 0. Chamaremos cada subconjunto de S_1 e S_0 , respectivamente.

De cada subconjunto S_i , extraiu-se os valores máximo, mínimo, médio e desvio padrão. Definiu-se uma única variável nebulosa, *Diagnóstico*, que possui apenas duas funções de pertinência: OK e não-OK.

Foram testados 3 diferentes formatos para as funções de pertinência da variável *Diagnóstico* [COX98]. Os três diferentes sistemas híbridos, definidos pelos 3 formatos de funções de pertinência, são referenciados como sistemas A, B e C, respectivamente.

Todos os três sistemas híbridos utilizam duas funções trapézio. No sistema A, a função *OK* é definida pelos pontos [0, 0, média0 e max0], onde média0 e max0 são os valores da média e o máximo do subconjunto S_0 , respectivamente. A função *não-OK* é definida pelos pontos [min1, média1, 1, 1], onde min1 e média1 são os valores mínimo e média do subconjunto S_1 , respectivamente.

No sistema B, as funções *OK* e *não-OK* são definidas pelos conjuntos de pontos [0, 0, min0, max0] e [min0, max0, 1, 1], respectivamente e, no sistema C, essas funções foram definidas como: [0, 0, média0, média0+2*desvio_padrao0] e [média1-2*desvio_padrao1, média1, 1, 1], respectivamente.

Nas *figuras 6 a 8*, encontram-se os gráficos correspondentes a cada um dos tipos de funções de pertinência usadas para o diagnóstico D_j . O desempenho apresentado pelo sistema híbrido em cada caso está descrito nas *tabelas 10 a 12*.

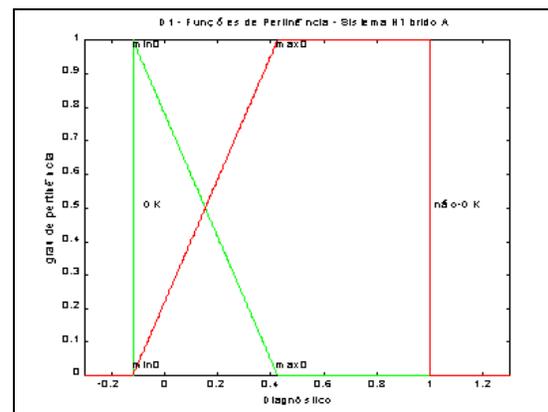


Figura 6. Funções de pertinência da variável difusa *Diagnóstico*, do sistema híbrido A, para o diagnóstico D_1 .

6.2 Funcionamento do Sistema Híbrido

Cada amostra presente no conjunto de dados é apresentada a cada uma das três redes neurais, correspondentes a cada diagnóstico que deve ser realizado. Como o funcionamento do sistema híbrido é idêntico para os três diagnósticos, apenas um deles será detalhado e os outros se darão da mesma forma.

A rede neural que realiza o diagnóstico D_i , ao receber como entrada uma amostra, irá gerar como resposta um valor entre 0 e 1. No modelo neural puro, esse valor era comparado a um *threshold* e a amostrada diagnosticada como 1 ou 0, conforme o caso.

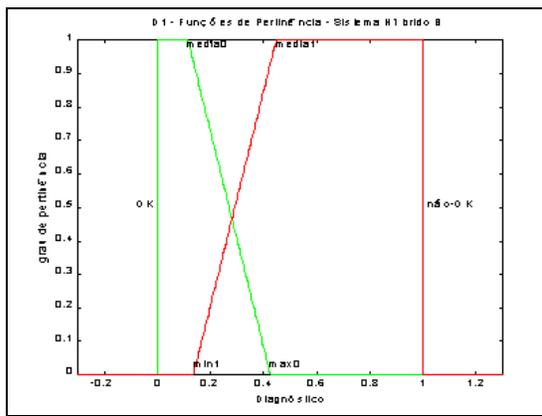


Figura 7. Funções de pertinência da variável difusa *Diagnóstico*, do sistema híbrido B, para o diagnóstico D_1 .

No modelo híbrido, a saída da rede servirá como entrada para o sistema difuso. O valor de saída passa a ser considerado como o valor da variável aleatória *Diagnóstico*, e os graus de pertinência em cada uma das funções nebulosas da variável são então avaliados. O conjunto nebuloso que obtiver o valor mais alto de pertinência, dado pela função correspondente, será o vencedor e à amostra será atribuída a classe correspondente.

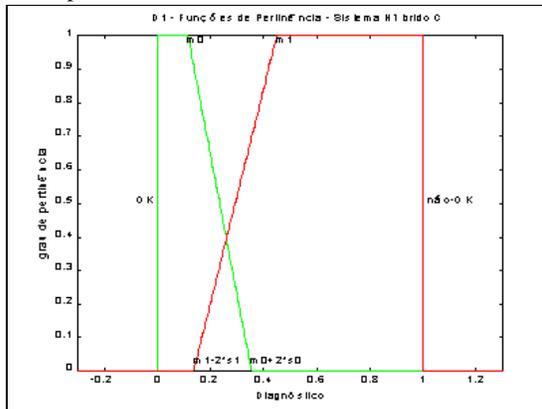


Figura 8. Funções de pertinência da variável difusa *Diagnóstico*, do sistema híbrido C, para o diagnóstico D_1 . Onde: m_i =média de C_i e s_i =desvio padrão de C_i .

6.3 Resultados obtidos

As tabelas 10 a 12 comparam o desempenho do sistema neural com o desempenho dos sistemas híbridos, em cada diagnóstico. É mostrado também o desempenho dos sistemas neural e híbrido, quando o mesmo é treinado com dois grupos distintos de variáveis. O primeiro grupo foi escolhido conforme o procedimento estatístico descrito anteriormente. O segundo grupo é o mesmo utilizado pelos especialistas da empresa que realiza a análise do óleo. Nas tabelas 10 a 12, esses grupos de variáveis estão discriminados na coluna *Var*, e são identificados como E_1 e E_2 , respectivamente.

Tabela 10. Comparação dos desempenhos dos diferentes sistemas no diagnóstico D_1 .

Conjunto de Dados C_1 – Diagnóstico I		
Var	Sistema Neural	
	% Acertos 0	% Acertos 1
E_1	85,62%	91,04%
E_2	89,87%	91,04%
Sistema Híbrido A		
	% Acertos 0	% Acertos 1
	E_1	57,13%
E_2	53,26%	100%
Sistema Híbrido B		
	% Acertos 0	% Acertos 1
	E_1	65,22%
E_2	83,70%	100%
Sistema Híbrido C		
	% Acertos 0	% Acertos 1
	E_1	57,13%
E_2	71,46%	100%

6.4 Comparações de Desempenho

O objetivo principal do sistema automatizado é eliminar o máximo de amostras não indicativas de problemas, reduzindo ao mínimo, idealmente zero, a exclusão de casos com problema, falso negativo. Verifica-se que o desempenho varia conforme o sistema (híbrido ou neural) sendo utilizado. Observa-se ainda que, na maioria dos casos, a diferença entre o desempenho do sistema neural puro, treinado com o grupo de variáveis E_1 , e o treinado pelo grupo E_2 , é razoavelmente pequena. Esse resultado confirma a validade do método de escolha de variáveis aplicado no experimento, conforme descrito anteriormente.

Tabela 11. Comparação dos desempenhos dos diferentes sistemas no diagnóstico D_2 .

Conjunto de Dados C_1 – Diagnóstico II		
Var	Sistema Neural	
	% Acertos 0	% Acertos 1
E_1	97,52%	80,80%
E_2	96,99%	79,20%
Sistema Híbrido A		
	% Acertos 0	% Acertos 1
	E_1	32,35%
E_2	35,43%	100%

Sistema Híbrido B		
	% Acertos 0	% Acertos 1
E_1	86,96%	75%
E_2	88,04%	100%
Sistema Híbrido C		
	% Acertos 0	% Acertos 1
E_1	53,30%	75%
E_2	56,17%	100%

Tabela 12. Comparação dos desempenhos dos diferentes sistemas no diagnóstico D_3 .

Conjunto de Dados C_1 – Diagnóstico I		
Var	Sistema Neural	
	% Acertos 0	% Acertos 1
E_1	82,06%	89,11%
E_2	44,30%	65,33%
Sistema Híbrido A		
	% Acertos 0	% Acertos 1
E_1	13,96%	100%
E_2	0,13%	16,67%
Sistema Híbrido B		
	% Acertos 0	% Acertos 1
E_1	81,52%	100%
E_2	91,30%	16,67%
Sistema Híbrido C		
	% Acertos 0	% Acertos 1
E_1	83%	100%
E_2	65,22%	33,33%

7 Conclusões

De um modo geral, pode-se concluir ainda que o papel do sistema híbrido é realizar uma correção da saída da rede neural. Inicialmente, a classificação de uma amostra é feita com base em um *threshold* pré-determinado. Quando se acrescenta um módulo nebuloso, algumas amostras anteriormente classificadas como do tipo 0, são classificadas como do tipo 1. Essa correção permite que amostras classificadas como falso negativo pela rede neural, sejam identificadas corretamente no novo sistema.

Como os três diagnósticos possuem características intrínsecas diferentes, as funções de pertinências que apresentam o melhor desempenho não são necessariamente de mesmo tipo. Verifica-se, de fato, que em cada diagnóstico os sistemas híbridos se comportam de forma diversa. Assim, para cada um deles, deve-se escolher o sistema híbrido mais adequado.

7.1 Dificuldades e futuras implementações

O conjunto de amostras não é grande o suficiente, além de conter poucas amostras dos grupos G_j , que contém as amostras cujos diagnósticos são iguais a 1. Por esse motivo, houve a necessidade de criar-se novas amostras artificialmente.

Para futuras implementações, espera-se dispor de um conjunto mais significativo de amostras, que re-tratem o problema com maior riqueza de detalhes e informações.

8 Referências Bibliográficas

- Cox, E. (1998). “The Fuzzy Systems Handbook – 2nd Edition”, *AP Professional*, pp. 1-165.
- Haykin, S. (1999), “Neural Networks: a comprehensive Foundation – 2nd Edition”, *Prentice-Hall, Inc.*, pp. 156-252.
- Hines, J. W. (1997). “Fuzzy and Neural Approaches in Engineering”, *John Wiley & Sons, Inc.*, pp. 6-52.
- Spiegel, M. R. (1978). “Probabilidade e Estatística - Coleção Schaum”, McGraw-Hill do Brasil. Pp. 435-449.
- Wonnacott, R. J, Wonnacott, T. H. (1985). “Fundamentos de Estatística”, LTC Editora S.A., pp. 234-267.