



**GRUPO VIII
GRUPO DE ESTUDO DE SUBESTAÇÕES E EQUIPAMENTOS ELÉTRICOS - GSE**

**DIAGNÓSTICO DE ESTADO DE TRANSFORMADORES, ATRAVÉS DA CROMATOGRÁFIA
E COM O USO DE REDES NEURAIS**

Vespucio Nunes de A. Barros Filho*	Ronaldo Ribeiro B. de Aquino	Aida A. Ferreira
CHESF/DOMA	UFPE/DEESP	UFPE/CiN

RESUMO

Este artigo mostra os principais resultados obtidos em [1], com relação a predição das falhas envolvendo a parte interna dos transformadores, usando como principal ferramenta o diagnóstico com base nas análises cromatográficas do óleo isolante do equipamento, associado ao uso de redes neurais para a definição do diagnóstico do equipamento analisado pelo critério IEC (International Electrotechnical Commission) [2]. A utilização das redes neurais artificiais (RNA), se mostrou bastante útil na determinação dos diagnósticos cromatográficos dos equipamentos pelo critério da IEC, e especialmente importante para também definir o diagnóstico mais provável para aquelas amostras cromatográficas que não apresentam um diagnóstico definido ou tabelado pela IEC.

PALAVRAS CHAVES

Transformadores, Monitoramento, Análises Cromatográficas, Redes Neurais, Perceptron em Múltiplas Camadas (MLP), Algoritmos Backpropagation e Rprop.

1. INTRODUÇÃO

Considerando o modelo atual do setor elétrico nacional, aonde as empresas de transmissão de energia elétrica recebem mais de acordo com a maior disponibilidade operacional dos seus equipamentos, bem como a necessidade de redução dos seus custos operacionais no sentido de viabilizar a própria sobrevivência da empresa num mercado cada vez mais competitivo e globalizado, estamos assistindo a um avanço na tecnologia utilizada nos processos de automatizações das instalações, com destaques por exemplo para a monitoração e diagnóstico de estado dos equipamentos de forma preditiva (on-line), ou seja sem indisponibilizar os equipamentos, como os grandes transformadores de potência, considerados como os principais equipamentos dentro da transmissão de energia.

Assim sendo é de suma importância que cada empresa, com base na análise de desempenho operacional dos seus transformadores, defina as suas prioridades, não só em função da importância relativa do equipamento para o sistema, mais principalmente optando para monitorar apenas aqueles parâmetros que possam diagnosticar de forma incipiente um tipo de problema no equipamento, com maior probabilidade de ocorrência para algumas famílias de equipamentos, e que dentro de um curto espaço de tempo possa o defeito evoluir para uma falha.

No caso do universo de transformadores e reatores a partir de 69kV analisados de 1990 a 2002, no sistema CHESF, verificamos que a média anual de falhas envolvendo a parte ativa foi de quase 2 (dois) equipamentos por ano, representando em média 15% das ocorrências e cujos custos associados para as recuperações são normalmente elevados, pois a vida útil dos transformadores e reatores são mensuradas pelo estado de sua isolação sólida.

Como técnica preditiva para a avaliação e diagnóstico de estado de transformadores imersos em óleo mineral isolante, destacamos o ensaio de análises de gases dissolvidos (DGA) ou análise cromatográfica do óleo isolante,

*CHESF/DOMA - Rua Delmiro Gouveia,333 Bongí, Edifício André Falcão, sala C330, CEP – 50761-901 Recife – PE - Brasil Tel.: (081) 3229.2994 - Fax: (081) 32293242 - E-mail: vespuccio@chesf.gov.br

que em função do tipo e da quantidade de gases combustíveis gerados pelo equipamento e absorvidos pelo óleo isolante, indica a presença de problemas (defeitos) ou falhas incipientes associadas a parte ativa do transformador. Dentro dessa análise, o critério utilizado por nós com maior êxito é o critério de diagnóstico pela IEC, seguido depois pelo critério de Rogers. O banco de dados utilizado contém 30613 amostras cromatográficas, feitas desde 1978 e associadas a 636 equipamentos com tensões de 69KV a 500KV. Mostraremos para o nosso caso, a maior eficiência do critério pela IEC com relação ao critério de Rogers, bem como a importância do uso de uma técnica de inteligência artificial (IA), denominada de redes neurais artificiais (RNA), para a emissão destes diagnósticos cromatográficos, além de extrapolar diagnósticos complementares para aquelas amostras que inicialmente não apresentam um diagnóstico definido ou tabelado pela IEC.

2. MONITORAMENTO E DIAGNÓSTICO PELA CROMATOGRAFIA

Embora a análise de gases dissolvidos no óleo isolante dos equipamentos, ou simplesmente análise cromatográfica, seja utilizada mundialmente a mais de vinte anos, ainda hoje é considerada como a melhor técnica preditiva para diagnosticar problemas internos aos transformadores. Nela utilizamos para a emissão do diagnóstico cromatográfico vários métodos ou critérios, com destaque para os critérios pela IEC / IEC revisada, o de Rogers / Rogers modificado, o de Pugh ou gás chave, o de Duval, e o de Dornenburg.

Desses métodos, apenas o da IEC / IEC revisada e o Rogers / Rogers modificado apresentam também diagnósticos de normalidade para os equipamentos, além dos diagnósticos de problemas já indicados em parte pelos outros métodos, sendo assim os mais usuais.

Além dos diagnósticos cromatográficos indicados pela análise do óleo, o parecer cromatográfico do especialista da manutenção deve considerar:

Gravidade do diagnóstico;

Análise comparativa das evoluções dos gases (por equipamento e por família de equipamento);

Condição / Período da vida em que se encontra operando;

Particularidades do projeto / fabricação;

Importância de nova amostra para confirmação dos resultados.

A cromatografia normalmente detecta a tempo um problema interno que não traga uma danificação do equipamento num curto espaço de tempo, do tipo:

Sobreaquecimento / ponto quente conexão;

Corrente de circulação entre núcleo e tanque;

Descargas entre ferragens e tanque;

Do banco de dados com 30613 amostras cromatográficas, obtemos os seguintes dados:

IEC = 70% das amostras com diagnósticos tabelados;

Rogers = 64% das amostras com diagnósticos tabelados;

IEC + Rogers = 77% das amostras com diagnósticos tabelados, sendo:

Diagnósticos não significativos - 68%;

Diagnósticos significativos - 23%;

Diagnósticos intermediários - 9%;

No sentido de avaliarmos a eficiência dos critérios pela IEC e Rogers, foi realizado um levantamento de 60 equipamentos com tensões à partir de 69kV até 500kV, pertencentes ao nosso banco de dados da cromatografia, que falharam por problemas internos ou foram retirados preditivamente, ou seja antes da falha, pela cromatografia.

Da Tabela 1, observamos que o critério pela IEC acertou no diagnóstico cromatográfico a natureza do problema com o problema efetivamente encontrado na inspeção interna em 80% (oitenta por cento) dos casos, enquanto que pelo critério de Rogers este número de acertos caiu para 62% (sessenta e dois por cento), mostrando assim a maior eficiência da cromatografia pelo critério da IEC. Além disso, a IEC já apresentava um maior número de amostras com diagnósticos definidos ou tabelados (21693 amostras ou aproximadamente 70% do total de 30613 amostras, contra 64% para o critério de Rogers), mesmo assim ficamos com 8920 amostras (aproximadamente 30% do total) sem diagnósticos tabelados pela IEC, e precisamos de uma forma de definirmos para cada um, dentre os dez diagnósticos definidos pela IEC originalmente, qual deles se aproxima mais da condição operacional interna real do equipamento.

TABELA 1 - Equipamentos que falharam internamente ou foram retirados pela cromatografia de 1981 a 2003 (julho)

Equipamentos Retirados	Quantidade	Diagnostico= Inspeção
Falha Interna	46	IEC = 35 (76%)
		ROGERS = 30 (65%)
Preditivamente	14	IEC = 13 (93%)
		ROGERS = 7 (50%)
Total	60	49 (82%)

3. DIAGNÓSTICO PELA CROMATOGRAFIA COM O USO DE REDES NEURAIS ARTIFICIAIS (RNA)

Para a solução do nosso problema, precisamos definir uma RNA que emita diagnósticos para as 21693 amostras similares aos da IEC, e depois extrapole os diagnósticos para as 8920 amostras restantes com base na previsão do especialista da engenharia de manutenção. Como no nosso caso, o método IEC apresentou melhor resultado, detalharemos a seguir as suas principais características para modelarmos a RNA.

A Tabela 2, apresenta como se obter os códigos gerados pela IEC através das relações dos gases dissolvidos no óleo isolante. Já a Tabela 3 mostra como estão distribuídos entre os códigos as amostras com diagnósticos tabelados.

TABELA 2 – Método pela IEC – Diagnósticos Tabelados

Relação entre gases (R)	Códigos da IEC		
	C_2H_2/C_2H_4	CH_4/H_2	C_2H_4/C_2H_6
$0,1 > R$	0	1	0
$0,1 \leq R < 1,0$	1	0	0
$1,0 \leq R < 3,0$	1	2	1
$R \geq 3,0$	2	2	2
CÓDIGOS COM DIAGNÓSTICOS TABELADOS :			
000 , 010, 020, 001, 110, 101, 102, 202, 021, 022			

TABELA 3 – Quantitativo de Diagnósticos Tabelados pela IEC

CÓDIGOS IEC	DIAGNÓSTICOS IEC	QUANTIDADE DE AMOSTRAS	%
000	Sem falha	3396	15,65
001	Defeito Térmico de Baixa Temperatura	1299	5,99
010	Descarga Parcial de Pequena Densidade de Energia	842	3,88
020	Defeito Térmico de Baixa Temperatura	9904	45,65
021	Defeito Térmico de Média Temperatura	1238	5,71
022	Defeito Térmico de Alta Temperatura	2570	11,85
101	Descarga de energia reduzida	527	2,43
102	Descarga de alta energia	1461	6,73
110	Descarga parcial de alta energia	125	0,58
202	Descarga de energia reduzida	331	1,53
TOTAL TABELADOS		21693	100

As referências [3] e [4] mostram o uso de RNA do tipo MLP (Multilayer Perceptron) com algoritmo Back-propagation para a solução de problemas dessa natureza, sendo este tipo de rede o ponto de partida para o nosso trabalho.

3.1 Modelagem da RNA

Sabemos que o critério pela IEC, considera na sua entrada para a emissão do diagnóstico cromatográfico de cada amostra, três relações de gases combustíveis, quais sejam: C_2H_2 / C_2H_4 , CH_4 / H_2 e C_2H_4 / C_2H_6 ; e que o número de diagnósticos possíveis são 10 (dez).

Partindo desta condição estabelecemos uma RNA cuja entrada seja a relação dos gases ou seja :

Entrada= [C_2H_2 / C_2H_4 , CH_4 / H_2 e C_2H_4 / C_2H_6]

Como o número de saídas tabeladas são 10 optamos por um vetor de saída binário que tenha apenas um elemento 1 (um), e os outros elementos 0 (zero), como mostrado na Tabela 4.

TABELA 4 – Códigos de saídas para a RNA

CÓDIGO IEC 1	CÓDIGO SAÍDA RNA
000	1000000000
001	0100000000
010	0010000000
020	0001000000
021	0000100000
022	0000010000
101	0000001000
102	0000000100
110	0000000010
202	0000000001

Dessa forma, nossa RNA deverá ter inicialmente na primeira camada 3 entradas, e na camada de saída 10 neurônios .

A Modelagem da RNA levou em consideração as regras heurísticas dos livros em [4] e [5], e o Benchmarking em [6], no sentido de melhorar o desempenho da rede.

Os dados de entrada da RNA foram selecionados, com 4000 amostras distribuídas nos conjuntos de treinamento (50%), validação (25%) e teste (25%).

Utilizamos o software MATLAB versão 6.5. para as simulações com o nosso banco de dados e com as RNA definidas.

Os dados de entrada foram representativos para cada classe (diagnóstico) a ser determinada pela rede neural, distribuídos de modo equilibrado, ou seja para os 4000 casos, coube 400 exemplos de cada uma das 10 classes (código IEC tabelado). Como duas classes de saída possuem menos de 400 exemplos, seus dados foram replicados até 400.

Os dados de entrada foram normalizados por colunas entre os valores máximos e mínimos. Já a codificação dos dados de saída em 10 campos binários foram alteradas para os números 0.1 e 0.9, a fim de fugirem das regiões de saturações da função de ativação sigmóide Logística adotada na saída da RNA. Na camada oculta utilizamos a função de ativação tangente hiperbólica.

A RNA adotada foi a do tipo MLP, com algoritmo Backpropagation de aprendizagem por correção de erro e por época, utilizando-se o Rprop ("Resilient propagation") como mostrado em [7].

Adotado como RNA satisfatória se o erro quadrático médio (MSE = Mean Squared Error) durante o treinamento for inferior a 0,5% (MSE < 0,005), sem crescimento do erro na validação, e feito treinamento com 1000 épocas (critérios de parada do treino da RNA).

Quantificado as saídas com diagnósticos corretos, pelo critério o "vencedor leva tudo", ou seja, o elemento maior representava o neurônio de saída ativado (1) e os outros estariam desativados (0).

Considerado inicialmente uma rede com 3 nós na entrada, uma camada oculta com 8 neurônios e uma camada de saída com 10 neurônios. Feitos acréscimos de 2 em 2 neurônios na camada oculta até atingirmos valores satisfatórios para o erro MSE como mostrado na Tabela 5, onde os resultados obtidos foram satisfatórios quando com 14 neurônios na camada oculta.

TABELA 5 - RNA 3-N-10, com algoritmo de aprendizagem RPROP

N – Número de neurônios na camada intermediária (oculta)	Erro MSE – Média por RNA para 10 simulações aleatórias	Número médio de erros de classificações por 1000
8	0,8472 %	21,7
10	0,8128%	20,7
12	0,7651%	21,1
14	0,5672%	13,4

Outra regra heurística indica que o número de conexões da RNA deve ser próximo a 10% do número de amostras de treinamento. Nesse artigo para 2000 exemplos de treinamento a rede adequada deve ter cerca de 200 conexões. Para o caso da RNA com 14 neurônios na camada oculta temos 206 conexões.

O algoritmo Rprop [7] é um algoritmo com taxa de aprendizagem adaptativa, ou seja, o ajuste dos pesos depende do sinal da derivada do erro com relação ao peso a ser ajustado, sendo normalmente de 1.2 para aumentar e de 0.5 para diminuir. Os Ajustes dos pesos são feitos na fase backward do treinamento, por época e para minimizar a função erro. O Rprop é um algoritmo de adaptação global, que realiza treinamento supervisionado por época em redes do tipo MLP.

O Rprop procura eliminar a influência negativa do valor da derivada parcial na definição dos ajustes dos pesos, pois utiliza apenas o sinal da derivada e não o seu valor. O sinal indica a direção do ajuste dos pesos, enquanto que o tamanho do ajuste é dado por um valor de atualização.

3.2 Resultados da RNA para as amostras com diagnósticos IEC tabelados

A RNA modelada de acordo com as condições do item 3.1 foi treinada em 10 inicializações com diferentes pesos, em concordância com o definido em [6] e apresentou os resultados mostradas na Tabela 6.

TABELA 6 - Resultados apresentados pela RNA 3 -14 -10

RNA	Épocas	MSE (Teste)	Acertos (em 1000)	Erros (em 1000)	Acertos (em 21693)	Erros (em 21693)
1	1000	0,005742	986	14	21049	644
2	1000	0,006268	985	15	20971	722
3	1000	0,005615	984	16	21008	685
4	734	0,004999	989	11	21184	509
5	706	0,004999	984	16	21006	687
6	1000	0,006346	984	16	21092	601
7	1000	0,005861	987	13	21166	527
8	1000	0,005642	986	14	21064	629
9	824	0,004994	989	11	21287	406
10	1000	0,005253	990	10	21170	523
Valor Médio	926	0,0055719	986	14	21100	593

Assim, conseguimos definir uma RNA que emite para o banco de dados cromatográficos, diagnósticos similares aos do método pela IEC com um erro médio quadrático MSE da ordem de 0,5% na média dos dez casos simulados; inclusive para o banco de dados total, para o qual a rede não foi treinada, onde no melhor caso a rede 9 erra apenas 406 diagnósticos dos 21693. O processo de convergência do erro (MSE) para a rede 9, durante o treinamento, esta mostrado na Figura 1.

A questão que passaremos a analisar a seguir é a capacidade da RNA treinada de fornecer diagnósticos aproximados para os casos Não Tabelados. Seria possível esta RNA, extrapolar diagnósticos para as 8920 amostras não tabeladas originalmente pela IEC?




FIGURA 1 – Treinamento da RNA caso 9

3.3 Resultados da RNA para as amostras com diagnósticos IEC não tabelados

Analisando o critério da IEC, para as combinações possíveis das três relações de gases, era pra termos 3.3.3 = 27 diagnósticos tabelados, no entanto, só temos 10 diagnósticos tabelados, mostrados na Tabela 7, faltando assim 17 diagnósticos.

Ao complementarmos as faixas associadas as relações dos gases pela IEC e distribuímos as 8920 amostras com diagnósticos não tabelados, obtemos a Tabela 8.

TABELA 7 - Agrupamento dos Códigos Tabelados

DIAGNÓSTICOS IEC	GÁS CHAVE (ppm)	CÓDIGOS TABELADOS
DETERIORAÇÃO NORMAL (I)	---	000
SOBREAQUECIMENTO (II)	CH ₄ , C ₂ H ₄ , C ₂ H ₆	020, 001, 021, 022
DESCARGA PARCIAL (III)	H ₂	010, 110,
ARCO ELÉTRICO (IV)	C ₂ H ₂	101, 102, 202
GRAVIDADE DO PROBLEMA EM ORDEM CRESCENTE : (I) => (II) => (III) => (IV)		

TABELA 8 - Agrupamento dos Códigos Não Tabelados

Diagnósticos do especialista com base na evolução do gás chave mais grave partindo de um tabelado	CÓDIGOS NÃO TABELADOS IEC
SOBREAQUECIMENTO (II)	002
DESCARGA PARCIAL (III)	011, 012
ARCO ELÉTRICO (IV)	100, 200, 120, 210, 220, 201, 111, 112, 121, 122, 211, 212, 221, 222

Os diagnósticos do especialista da manutenção para os códigos não tabelados foram baseados na simulação de evolução do gás chave mais importante, de acordo com a gravidade do problema, e partindo-se de um diagnóstico tabelado pela IEC mais “adequado” (próximo).

Feito a alimentação da rede neural, com cada um dos 17 subconjuntos de diagnósticos não tabelados da IEC, comparando-se a natureza dos problemas indicados pela RNA com as expectativas de diagnósticos do especialista da manutenção. A RNA acertou em 14 dos 17 códigos não tabelados, conforme Tabela 9.

TABELA 9 Resultados da simulação para os Códigos Não Tabelados

CÓDIGOS NÃO TABELADOS	DIAGNÓSTICOS DO ESPECIALISTA	DIAGNÓSTICO DA RNA
002	sobreaquecimento	arco
011 , 012	descarga parcial	arco
14 demais	arco	arco
Total = 17	RNA acertou 14 códigos (82%)	

No sentido de melhor avaliarmos a validade desses diagnósticos estimados para as amostras inicialmente sem diagnósticos definidos pela IEC, foi feito um levantamento de equipamentos que falharam e que antes das mesmas, indicavam diagnósticos IEC não tabelados, com os respectivos resultados das inspeções internas realizadas depois das falhas, sendo obtido para 10 equipamentos os dados da Tabela 10.

Para os 10 equipamentos, verificamos que a RNA apresentou um diagnóstico igual ao do especialista em 9 casos, havendo apenas divergência quanto ao código 002, que segundo o especialista seria indicativo de sobreaquecimento ou defeito térmico enquanto que para a RNA seria arco elétrico. Coincidentemente, no nosso banco de dados encontramos apenas para o código 002, uma situação aonde a RNA tinha razão quanto ao seu diagnóstico, e outra situação aonde quem tinha razão era o especialista da manutenção (ver Tabela 10).

TABELA 10 - Histórico com diagnósticos pelas inspeções internas para Códigos Não Tabelados

EQUIPAMENTO	NR.SÉRIE	DATA	INSPEÇÃO INTERNA	DIAGNÓSTICOS	
TRAFO 69KV	5100349	16/05/85	CURTO-CIRCUITO (ARCO) ENTRE ESPIRAS 13.8KV	5/03/85 102	16/05/85 122 - ARCO
TRAFO 230KV	117200-2	01/10/87	CURTO-CIRCUITO (ARCO) ENTRE ESPIRAS 13.8KV	18/3/87 000	01/10/87 002-ARCO 002- Sobre- aquecimento
REATOR 230KV	5100455	24/08/88	SOBREAQUECIMENTO BOBINA REATOR 230KV	3/12/87 002	25/08/88 002-ARCO 002- Sobre- aquecimento
AUTO TRAFO	8234850103	05/04/90	CDC - ARCO/DESGASTES CONTATOS INVERSORA	7/11/89 000	05/04/90 200 - ARCO
TRAFO 230KV	46424	21/01/91	CURTO-CIRCUITO (ARCO) ENTRE ESPIRAS 13.8KV	6/11/90 000	21/01/91 100 - ARCO
REATOR 230KV	5100456	29/09/91	ARCO BLINDAGEM ENROLAMENTO 230KV	7/08/91 002	29/09/91 112 - ARCO
REATOR 230KV	SP2106	21/01/92	ARCO / EXPLOÇÃO BUCHA 230KV	20/1/91 002	21/01/92 122 - ARCO
TRAFO 230KV	569989	19/07/95	CDC - ARCO / DANOS CHAVE DESVIADORA	30/3/95 000	19/07/95 100 - ARCO
TRAFO 500KV	218205/2	26/09/98	CURTO-CIRCUITO (ARCO) ENTRE ESPIRAS 500KV	14/9/98 020	26/09/98 122 - ARCO
TRAFO 230KV	D203254	09/12/02	CURTO-CIRCUITO (ARCO) ENTRE ESPIRAS 132KV	6/08/02 020	09/12/02 100 - ARCO

A medição da eficiência no resultado obtido pela rede neural artificial, bem como do diagnóstico dado pelo especialista da manutenção para as amostras com diagnósticos não tabelados, foi feita baseando-se na comparação da natureza do problema encontrado na inspeção interna do equipamento e os diagnósticos indicados pelos mesmos (sobreaquecimento – descarga parcial – arco elétrico).

4. CONCLUSÕES

Os resultados obtidos pela análise cromatográfica utilizando-se o método IEC (80%) se mostraram mais eficientes que os de Rogers (62%) e atendendo a um número maior de amostras com diagnósticos tabelados.

A aplicação de redes neurais, no banco de análises cromatográficas da empresa com 21693 amostras, para a emissão de diagnósticos similares aos da IEC, foi bastante satisfatória.

A rede neural MLP 3-14-10 número 9 definida no item 3.2, também se mostrou eficiente, quando extrapolou para as 8920 amostras sem diagnósticos tabelados pela IEC, diagnósticos 82% similares aos indicados pelo especialista da engenharia de manutenção.

Recomendamos que seja adotado para os 17 códigos inicialmente não tabelados pela IEC, os diagnósticos definidos na dissertação pelo especialista da engenharia de manutenção, e que foram também confirmados em

sua maioria pela RNA modelada neste artigo, estabelecendo assim um “ diagnóstico via IEC ” para cada uma das 8920 amostras não tabeladas.

5. BIBLIOGRAFIA

- [1] Barros Filho, Vespucio N A, Dissertação de Mestrado “Monitoramento e diagnóstico de estados de grandes transformadores, com ênfase para o diagnóstico pela cromatografia com o uso de redes neurais”- UFPE , Recife-PE, Setembro, 2003.
- [2] IEC – International Electrotechnical Commission – “Interpretation the analysis of gases in transformer and other Oil-filled impregnated Electrical Equipment in Service” , CEI – IEC – 599, First Edition, 1978.
- [3] Guardado, J.L., Naredo,J.L., Moreno, P., and Fuerte, C.R., - “A Comparative Study of Neural Network Efficiency in Power Transformers Diagnosis Using Dissolved Gas Analysis”, IEEE Transactions on Power delivery, October, 2001.
- [4] Haykin, Simon, “Redes Neurais – Princípios e práticas”, Bookman, Segunda Edição, Porto Alegre – RS- 2001.
- [5] Ludermir, Teresa B., Braga, Antônio de Pádua, e Carvalho, André Carlos P.L.F., “Redes Neurais Artificiais: Teoria e Aplicações”, Editora LTC, Rio de Janeiro - RJ, Brasil, 2000.
- [6] Prechelt, Lutz, PROBEN1- “A Set of Neural Network Benchmark Problems and Benchmarking Rules” University of Karlsruhe, September, 1994.
- [7] Riedmiller, Martin and Braun, Heinrich “A Direct adaptive Method for faster Back propagation Learning: The RPROP Algorithm “, University of Karlsruhe, 1993.