

PROCESSAMENTO INTELIGENTE DE ALARMES VIA REDES NEURAS ARTIFICIAIS: UMA CONTRIBUIÇÃO PARA A SOLUÇÃO DO PROBLEMA EM NÍVEL DE SUBESTAÇÃO

MÁRIO S. NASCIMENTO JR^{1(*)}, MARCELO B. TOLLER^{2(**)}, GHENDY CARDOSO JR²
ADRIANO P. MORAIS², GUSTAVO D. FERREIRA²

¹*Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal do Pará
Núcleo de Energia, Sistemas e Comunicações (NESC)*

²*Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Santa Maria
Centro de Estudos em Energia e Meio Ambiente (CEEMA)*

E-mail: mario.sergio@sysdata.com.br, mtoller@mail.ufsm.br***

Abstract - This work deals with the proposal of a new methodology to the problem of alarm processing. The methodology makes use of a neural network (Generalized Regression Neural Network – GRNN), whose task is to filter the generated raw alarms in an event fault, pointing out the main alarm related. This application was implemented in the Main Substation of Albras, producer of aluminum ingots. A neural network was developed as an alarm processor, due to their great generalization capacity. Thus, when the alarm processor is fed with noising alarms, it's even possible to get reliable answers.

Keywords - Alarm Processing, neural networks, supervisory system.

Resumo - O presente trabalho propõe uma nova metodologia para o processamento de alarmes. A metodologia faz uso de uma rede neural (*Generalized Regression Neural Network* – GRNN), cuja finalidade é filtrar os alarmes gerados durante uma falta, e disponibilizar apenas o alarme principal relacionado ao evento. O aplicativo foi implementado na subestação principal da Albras, produtora de alumínio em lingotes. A escolha de uma rede neural para o desenvolvimento de um processador de alarmes foi motivada com base na capacidade de generalização que as mesmas possuem, além da velocidade de processamento. Com isso, mesmo que o processador de alarmes seja alimentado com sinalizações de alarmes apresentando pequenas distorções nas informações, durante a recepção, ainda é possível obter-se um resultado confiável.

Palavras-chave - Processamento de Alarmes, redes neurais, sistema de supervisão.

1 Introdução

A utilização de ferramentas computacionais de apoio à tomada de decisão tem se tornado imprescindível nas subestações e centros de controle, principalmente no que diz respeito ao restabelecimento do mesmo ao seu estado normal de operação. Vários trabalhos têm sido publicados a respeito, sugerindo metodologias eficazes e de utilização em tempo real, integradas aos sistemas de supervisão e controle.

Este grande interesse é devido à necessidade em se diminuir a possibilidade de erro de análise durante momentos críticos por qual passa o pessoal da operação. Fato esse relevante no Setor Elétrico Brasileiro. Dessa forma, a necessidade de se utilizar ferramentas computacionais eficientes, que atendam as necessidades da operação em tempo real, é reforçada mediante a utilização conjunta com os sistemas de supervisão e controle (Cardoso Jr., 2003).

Atualmente, há um crescente aumento na quantidade de equipamentos que necessitam de monitoração, aumentando, conseqüentemente, o número de alarmes supervisionados em uma subestação. Dependendo do evento, o volume de mensagens de alarmes pode atingir a ordem de centenas por minuto. Tais informações devem ser analisadas em tempo hábil por parte dos operadores exatamente nos momentos de maior estresse, de modo a restaurar o sistema ao seu estado de funcionamento normal e seguro.

Diante de tais fatos, o desenvolvimento de ferramentas computacionais para a filtragem de alarmes

redundantes tem se tornado popular.

A função de um processador de alarmes é agrupar, selecionar e apresentar ao operador apenas os alarmes mais importantes (Fu et al., 1995). Conforme Vale et al. (2002) o processador inteligente de alarmes deve também sugerir ações de controle corretivas quando necessário.

Sistemas especialistas, redes neurais, algoritmos genéticos, grafos estruturados e lógica fuzzy são as técnicas sugeridas para a construção de ferramentas para o processamento de alarmes. Porém, apenas os sistemas especialistas se sobressaem em aplicações reais, ficando as outras no campo acadêmico.

Este trabalho propõe uma metodologia para o desenvolvimento de um processador inteligente de alarmes com base nas redes neurais, mais especificamente, as GRNN (*Generalized Regression Neural Network*). Os alarmes considerados são os do sistema de retificação das Reduções de alumínio da Albras – Alumínio Brasileiro S.A. Entre as principais vantagens do método, cita-se a facilidade de implementação em sistemas reais de grande porte, já que o mesmo é formulado de forma modular.

2 Processamento de Alarmes

Grandes quantidades de informações de alarmes são aquisitadas pelo sistema de supervisão, principalmente quando da ocorrência de uma falha grave. Caso ocorra um defeito pouco comum, a ação do operador pode ser desviada da real natureza do pro-

blema, dificultando o processo de restauração do sistema elétrico (Kirschen & Wollenberg, 1992).

Os recentes avanços no campo das comunicações e tecnologias digitais possibilitaram um aumento considerável no número de variáveis a serem monitoradas e no número de alarmes a serem processados. Diversos tipos de programas computacionais têm sido propostos e desenvolvidos para o processamento de alarmes. Os programas devem focar a atenção do operador e ajudá-lo na evolução do estado do sistema de potência, fornecendo um resumo das condições anormais em que o mesmo se encontra.

Vários métodos têm sido sugeridos e, em alguns casos, implementados, tais como: mecanismos de filtragem, esquemas de prioridades e agrupamento.

Devido à semelhança existente entre os alarmes gerados e padrões de identificação, as redes neurais passaram a ser utilizadas na identificação das causas desses alarmes. Os sistemas especialistas baseados em regras, também são muito utilizados no processamento de alarmes. Entre esses dois métodos, as redes neurais apresentam mais flexibilidade (Kirschen & Wollenberg, 1992).

O processamento de alarmes passou a melhorar o nível das mensagens disponibilizadas ao operador, melhorando, com isso, seu tempo de resposta diante da falta, e auxiliando-o na análise do problema.

3 Redes Neurais Artificiais

A minimização dos esforços humanos tem sido um dos objetivos da engenharia, que vem desenvolvendo técnicas e implementações que possam realizar as mesmas tarefas que o homem. Dentre essas técnicas e implementações, encontram-se as Redes Neurais, que devido à capacidade de aprendizado, generalização e de classificação, são utilizadas em reconhecimento de padrões, controle, modelagem, aproximação de funções, entre outras.

3.1 Neurônio Artificial

Um dos grandes desafios dos pesquisadores foi criar um modelo de neurônio artificial com características similares ao neurônio biológico, sendo o modelo mais utilizado aquele proposto por McCulloch & Pitts (Biondi Neto, 1997) (ver Fig. 1).

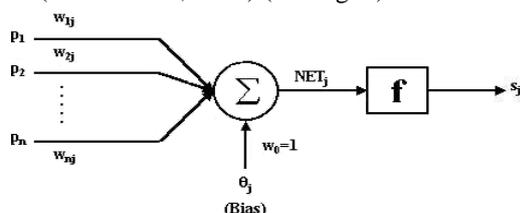


Figura 1 - Modelo de McCulloch & Pitts.

Os elementos p_1, p_2, \dots, p_n constituem as entradas do modelo. Os pesos $w_{1j}, w_{2j}, \dots, w_{nj}$, que podem ser

positivos ou negativos, determinam o efeito de excitação ou inibição sobre o neurônio de destino. Estes elementos são combinados e somados, constituindo o NET_j (regra de propagação), sendo que o NET_j é definido como a soma ponderada entre a entrada e os pesos (Eq. (1)). Esta regra é chamada de regra sigma (Krose & Smagt, 1995).

$$NET_j = \sum_i^n w_{ij} p_i + \theta_j \quad (1)$$

onde, a saída do neurônio é constituída por:

$$S_j = f(NET_j) \quad (2)$$

Geralmente a função de ativação f é uma função não-decrescente da entrada total da unidade (Krose & Smagt, 1995). Os tipos mais usados são: degrau, degrau simétrico, linear, pseudolinear, sigmóide e tangente hiperbólica (Biondi Neto, 1997).

3.2 Topologias das Redes

Existem, basicamente, dois tipos de topologias: as *feedforward*, onde não existe realimentação alguma; e as *recorrentes*, onde existe realimentação, dando, assim, importância às propriedades dinâmicas da rede (Biondi Neto, 1997; Krose & Smagt, 1995). Como exemplo de redes *feedforward* temos o Perceptron e o Adaline; e de redes *recorrentes*, Hopfield e Máquina de Boltzmann (Krose & Smagt, 1995).

Entre as duas topologias citadas anteriormente, a mais utilizada é a *feedforward*, podendo ser implementada em processadores comuns, não exigindo muita memória em comparação com a outra topologia (Schaedler et al., 2003). Esta topologia pode possuir múltiplas camadas interconectadas, sendo conhecida como *multi-layer network*, conforme a Figura 2.

3.3 GRNN (Generalized Regression Neural Network)

A rede GRNN é uma variação da rede de base radial. Apresenta grande capacidade de generalização, sendo bastante utilizada na aproximação de funções. Seu funcionamento é semelhante ao da rede PNN (*Probabilistic Neural Network*), que determina limites de decisão entre padrões, embora a GRNN resulte em valores contínuos (Specht, 1988; Specht, 1991; Cardoso Jr., 2003).

Estrutura da GRNN pode ser vista na Figura 2.

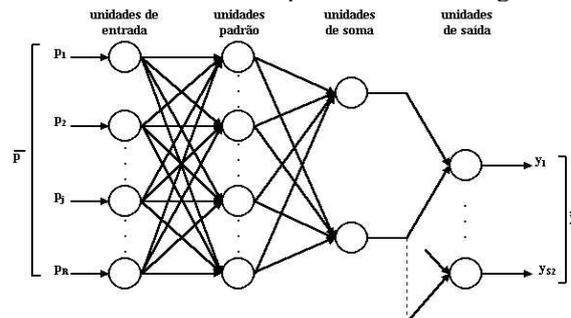


Figura 2 - Estrutura da Rede GRNN, Tipo Feedforward.

Cada neurônio da unidade padrão é um centro de agrupamento, sendo que o número de neurônios dessa camada é igual ao número de exemplares utilizados durante o aprendizado.

Quando um novo padrão é apresentado à rede, é calculada a distância entre este novo padrão e os exemplares previamente armazenados. O valor absoluto destas diferenças é somado e multiplicado pelo bias, sendo então enviados a uma função de ativação não linear (Cardoso Jr., 2003).

Uma exponencial é utilizada como função de ativação, sendo o bias ajustado para $0.8326/spread$, onde *spread* é o espalhamento, ou a abertura da exponencial utilizada (Fig. 3).

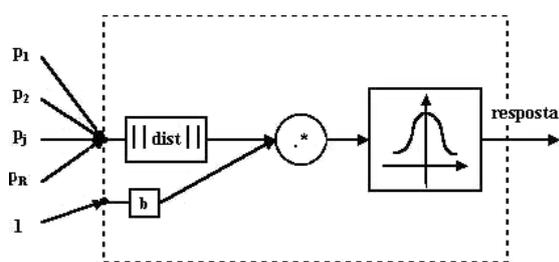


Figura 3 - Unidade Padrão da GRNN.

A performance da rede é influenciada pelo ajuste do bias (*spread*) e pelos padrões armazenados. Portanto, para um valor de *spread* muito grande a rede passa a generalizar demasiadamente, enquanto que um valor muito pequeno torna a rede incapaz de generalizar (Specht, 1991).

A saída das unidades da camada padrão é enviada à camada de soma. O número de unidades que compõem esta camada corresponde ao número de observações (saídas desejadas). As unidades de soma têm a função de realizar o somatório da saída das unidades padrão, de acordo com o número de observações que cada exemplar representa. Este número de observações varia conforme o número de saídas desejadas. As unidades da camada de saída simplesmente dividem cada um dos somatórios resultantes das unidades de soma pelo somatório total de todas as unidades que compõem a camada de soma (Cardoso Jr., 2003).

A rede GRNN pode ser utilizada para fins de previsão, modelagem, mapeamento, interpolação ou controle. As principais vantagens são (Specht, 1991):

- O processo de aprendizado ocorre em um único passo;
- Fácil implementação;
- O resultado é limitado aos valores máximos e mínimos das observações;
- Não utiliza função de erro como critério de avaliação.

Como desvantagem, destaca-se o fato das mesmas requererem bastante esforço computacional para avaliar novos pontos quando o conjunto de padrões utilizados durante a aprendizagem for muito grande.

4 Metodologia de Solução

A Subestação Principal (SE) da Albras é a unidade da fábrica responsável pelo fornecimento de energia para a fabricação do alumínio, da qual se espera regime contínuo de operação e fornecimento de energia. O fornecimento da energia para as Reduções de alumínio é feito através do sistema de retificação, composto por seis retificadores a diodo mais VCR em paralelo, alimentados por seis transformadores defasadores de 34,5kV/770V (ver Fig. 4).

Os alarmes gerados por ocasião de um defeito no sistema de retificação devem ser rapidamente interpretados e diagnosticados por parte dos operadores para que o sistema seja restaurado ao seu estado seguro e normal, considerando que fica a critério do operador a aceitação ou não da sugestão gerada pelo processador de alarmes.

4.1 Modelamento

Procurou-se fazer um modelamento compacto do sistema de alarmes, independente da configuração do sistema elétrico.

A Tabela 1 apresenta os alarmes do sistema Redução I, sendo que os sistemas de Redução II, III e IV apresentam descrição de alarmes semelhantes.

Tabela 1 - Alarmes do sistema Redução I.

Relé Acionado	Descrição
5ERY1X	Trip de Emergência Eletronorte ou Redução
71F/50	Falha de Diodo
64	Falha à Terra RF
DEM1	Trip de Emerg. Sala de Barramentos
48T	Tempo de Atraso Mudança de Tap LVR1
48TR	Tempo de Atraso Mudança de Tap LVR2
5ERY1	Sinal de Trip da Redução
76	Sobrecorrente DC
26W	Temperatura Alta Água Desionizada
69W	Água Desionizada sem Fluxo
49WA2	Sobrecarga Trocador de Calor Água-Ar (2º Estágio)
49W	Sobrecarga Bomba Água Desionizada
47	Subtensão Serviço Auxiliar
71F2	Falha Absorvedor de Surtos
96-2	Operação Relé Buchholz (2º estágio)
63T	Válvula de Alívio de Pressão
50/51	Sobrecorrente AC
67G	Sobrecorrente AC Terra
33W	Baixo Nível de Água Desionizada
49WA1	Sobrecarga Trocador de Calor Água-Ar (1º Estágio)
49AF	Sobrecarga Refrig. Cubículo Retificador
26H	Temperatura Alta Cubículo de Ar RF
96-1	Operação Relé Buchholz (1º estágio)
33Q	Baixo Nível de Óleo
26Q	Temperatura de Óleo Alta
49QA	Sobrecarga Trocador de Calor Óleo
48M	Partida do Serv. Aux. Fora de Sequência

Os alarmes apresentados na Tabela 1 são aquisitados pelo Sistema de Supervisão e Controle da Subestação Principal da Albras (SCOSE), desenvolvido no RSView32 Works, da Rockwell Software.

4.2 Conjuntos de Treinamento e de Teste

O conjunto de treinamento foi obtido a partir da leitura e estudo dos diagramas c.c. de proteção. Após a elaboração de um estudo que relaciona as seqüências de alarmes com o alarme associado à causa principal do defeito, foi realizada uma entrevista com o pessoal da operação, de modo a confirmar a consistência da mesma.

O padrão de treinamento é formado por um conjunto de bits, que correspondem aos alarmes gerados pelo sistema de supervisão quando da ocorrência de uma falha. Os alarmes compõem uma palavra de 27 bits, sendo que cada bit representa um alarme do sistema de Redução I. A disposição dos alarmes é a mesma mostrada na Tabela 1. Além dos 27 bits utilizados para os alarmes, também são utilizados três bits adicionais para informar o *status* do disjuntor do transformador principal (DM), do transformador regulador (DL) e transformadores dos retificadores (DR) (ver Fig. 4).

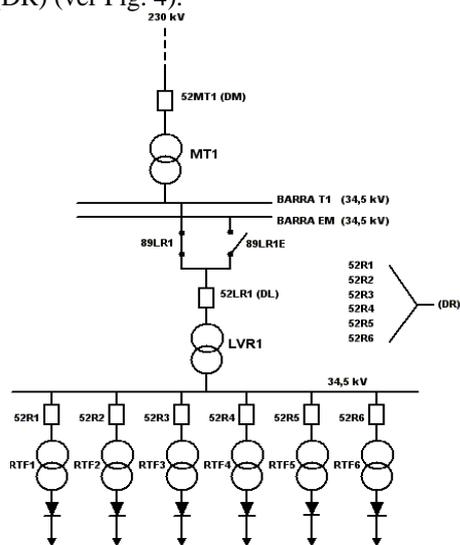


Figura 4 - Diagrama Unifilar da Redução I e disjuntores DM, DL e DR.

Devido à existência de seis transformadores retificadores para cada redução, houve a necessidade de se utilizar um esquema que pudesse determinar a abertura de qualquer um dos disjuntores associados aos transformadores retificadores. Assim, a abertura de qualquer disjuntor associado a um dos seis transformadores retificadores seta o bit "DR", o qual é utilizado pelo processador de alarmes.

A Tabela 2 mostra os 49 padrões utilizados no treinamento da rede, incluindo também a resposta da rede para o caso de alarmes (Alr) não relacionados ao desligamento, e também para o caso de falta de informações para o processamento (SI).

Estes padrões de alarmes podem ser facilmente modificados ou reajustados.

Os exemplares de teste foram criados a partir do conjunto de treinamento. Para a geração dos exemplos de teste, desenvolveu-se um gerador de casos aleatórios no MATLAB®. Desse modo, procurou-se simular as várias situações de alarmes que pudessem chegar ao Sistema de Supervisão e Controle (SCOSE), incluindo alarmes indevidos ou perda de informação.

Tabela 2 - Alguns padrões utilizados no treinamento da GRNN.

Padrão	Relés Atuados	Causa	Ação	Classe
1	5ERY1X, DEM1, 48TR, DR, DL	DEM1	Trip	1
2	5ERY1X, 5ERY1, DR, DL	5ERY1	Trip	2
3	71F/50, 76, 63T, 96-1, DR, DL	76	Trip	3
4	76, 49WA2, 49W, 96-2, 33Q, 26Q, 49QA, DR	76	Trip	3
5	26W, 49W, DR	49W	Trip	4
6	64, 67G, 26H, DR, DL	67G	Trip	5
7	49WA1, 49AF	Alr	Alarme	6
.
.
49	-	-	SI	16

Cada amostra procura evidenciar a situação do surgimento de alarmes possíveis, ou não, durante uma situação de falta ou advertência. As amostras foram geradas através da escolha aleatória de uma posição qualquer, dentro de cada um dos 49 exemplares do conjunto de treinamento, formando uma amostra do conjunto de teste. Para cada conjunto de teste foi atribuído um total de 100 amostras (quantidade considerada como suficiente para testar o processador de alarmes).

A possibilidade de surgimento de erros de comunicação, ou de ausência de informação (o sistema não recebe o sinal de alarme, embora o relé tenha atuado), foi simulada por meio da introdução de erros em 1, 3, 5 e 7 bits, em cada um dos 49 exemplares do conjunto de treinamento. A quantidade de conjuntos de teste assim gerados foi de $(49 \times 4) = 196$, com 100 amostras cada.

Esse procedimento foi utilizado com o intuito de definir a performance da rede mediante a possibilidade de erro (ruído) no recebimento de informação de alarme pelo sistema de supervisão.

No caso da rede GRNN a resposta é obtida em um único passo, não sendo necessário treinamento iterativo. Assim, basta adicionar um padrão de alarmes ao conjunto de treinamento, para que o mesmo seja imediatamente utilizado pela rede. Para que a GRNN generalize adequadamente, é necessário que o *spread* tenha um valor que não seja muito grande. Um valor alto do *spread* faz com que a rede generalize demasiadamente, enquanto que um muito pequeno torna a rede incapaz de generalizar (Specht, 1991). Portanto, o ajuste do *spread* foi feito através de verificação, e depois de vários testes chegou-se a um valor satisfatório para *spread* igual a 0.29.

4.3 Validação

A rede GRNN, utilizada pelo Processador de Alarmes foi equiparada a um processador utilizando uma rede MLP com o algoritmo *backpropagation*, treinada com o mesmo conjunto de treinamento utilizado pela rede GRNN.

Após o treinamento das redes, foram apresentados os 196 conjuntos de testes descritos anteriormente. Para a rede MLP, foram testados vários ajustes nos seus parâmetros, bem como na sua estrutura, até se chegar aos valores considerados adequados. Os parâmetros utilizados no treinamento da rede MLP com algoritmo de treinamento *backpropagation*, cuja estrutura apresenta 32 neurônios na camada de entrada, 40 neurônios na camada escondida, e 16 na camada de saída, foram:

- Taxa de aprendizagem adaptativa;
- Coeficiente de momentum igual a 0.9;
- Tolerância de erro de 10^{-6} ;
- Função de ativação sigmoidal;
- Número máximo de iterações igual a 10000.

A rede MLP foi utilizada para se ter uma idéia da performance e eficiência da rede GRNN frente a um dos algoritmos mais utilizado nos diversos campos de aplicação.

5 Resultados

5.1 Processador de Alarmes com a rede GRNN

O processador de alarmes tem como núcleo principal a GRNN, com a função de filtrar o alarme principal associado ao conjunto de alarmes gerados durante uma falta. Porém, esta filtragem resulta em uma palavra com valores ponderados, ou seja, cada elemento que compõe o código de saída possui um determinado percentual que corresponde ao seu peso na saída.

Para a utilização desse tipo de saída ponderada, é necessário que seja feito um tratamento, adaptando esses dados de saída. Isto porque o processador de alarmes utiliza dados binários para retornar uma resposta condizente com o alarme principal filtrado. Assim, é utilizado um valor de corte durante a análise dos resultados, transformando esses valores ponderados na forma de 0 (zero) ou 1 (um).

Durante a fase de avaliação das respostas provavelmente corretas, ou seja, da capacidade de reconhecimento dos alarmes pelo processador, foram feitas análises das saídas da GRNN, da seguinte forma:

- Se o valor apresentado pela GRNN for maior que o valor de corte (> 0.5) especificado, então a esse valor é atribuído 1;
- Se o valor apresentado for igual ou menor que o valor de corte especificado (≤ 0.5), então a esse valor é atribuído 0.

Na Tabela 2 a coluna classe representa os 16 padrões de alarmes que a GRNN utiliza para fazer a filtragem do alarme principal. Então cada uma destas classes existentes corresponde ao elemento principal de cada padrão de alarmes utilizados para treinamento.

Estas classes são apresentadas à GRNN através do vetor de classes, que faz a função de professor para o modelo neural. A saída da GRNN é na forma de vetor, onde seus elementos mostram o grau de semelhança que cada elemento do vetor possui com relação a sua respectiva classe.

Também foi utilizado o mesmo tipo de tratamento para os dados de saída obtidos por uma rede neural MLP com o algoritmo de treinamento *backpropagation*.

A Tabela 3 apresenta os resultados dos testes de todos os casos gerados (196 conjuntos com 100 amostras cada).

Tabela 3 - Percentual de acertos da GRNN e Backpropagation.

Erro de Recepção dos bits pelo Sistema de Supervisão		Percentagem de Acertos da Rede
1 bit	GRNN	91,08%
	BP	80,57%
3 bits	GRNN	75,96%
	BP	53,14%
5 bits	GRNN	61,61%
	BP	38,24%
7 bits	GRNN	47,41%
	BP	30,86%

Fazendo-se a comparação dos valores percentuais de cada modelo neural, verificou-se a superioridade da GRNN com relação ao modelo com o algoritmo *backpropagation*, levando-se em conta que foram considerados os mesmos conjuntos de treinamento e teste. Tais resultados estão de acordo com os testes realizados por Marquez & Hill (1993) e Frost & Karri (1999).

5.2 Casos Reais de Alarmes do Sistema Redução

Dos casos registrados pelo processador de alarmes, foi extraído um caso representando a atuação de alarmes de advertência, e oito casos representando atuações com trip. Para estes casos, a taxa de acertos foi de 100%, de acordo com a avaliação dos operadores. A Tabela 4 apresenta cada um destes casos, sendo um desses comentado em seguida.

Nota-se que para o Caso 1, os componentes deste padrão são os elementos 49WAX1 e 49AF (Tabela 2 – Padrão 7). Apesar deste caso apresentar um elemento a mais 49QA (o qual gera apenas informação de alarme), com relação a Tabela 2, mesmo assim o processador de alarmes apresentou a resposta Alm, indicando somente alarme de advertência, o que de fato está correto, segundo os operadores da subestação.

Tabela 4 - Casos reais obtidos pelo sistema de supervisão.

CASOS	RELÉS ACIONADOS	REPOSTA DO PROCESSADOR
Caso 1	49WA1, 49AF, 49QA	Alr (Alarme)
Caso 2	69W, 47, DR	47
Caso 3	71F/50, 76, DR	76
Caso 4	5ERY1X, 5ERY1, DR, DL	5ERY1
Caso 5	69W, 33W, DR	47
Caso 6	5ERY1X, 5ERY1, DL, DM	5ERY1
Caso 7	5ERY1X, 5ERY1, 49WA2, 49W, 49WA1, 49AF, 49QA, DR, DL, DM	5ERY1
Caso 8	5ERY1X, 5ERY1, DL	5ERY1
Caso 9	71F/50, DR, DL	71F/50

A Figura 5 mostra a interface do processador de alarmes, com os elementos em questão e a resposta para o caso 1.



Figura 5 – Processamento de Alarmes para o Caso 1.

6 Conclusão

A utilização de redes neurais para modelamento dos componentes de uma subestação, juntamente com seus conjuntos de alarmes, permite uma grande flexibilidade e viabilidade de aplicação em sistemas reais de grande porte. A GRNN tem a capacidade de classificar conjuntos de alarmes mesmo com poucos exemplares de aprendizado. Assim, padrões de alarmes que se aproximam daqueles existentes na matriz de conhecimento da GRNN são classificados com uma alta confiabilidade. A inclusão de uma classe indicando falta de informação (SI) faz com que a GRNN não apresente uma classificação errônea devido à presença de dados de alarmes conflitantes.

O algoritmo *backpropagation* foi utilizado para verificar a viabilidade em se utilizar a GRNN no desenvolvimento do processador de alarmes, já que é a arquitetura neural mais difundida e utilizada em tais aplicações. Deste modo, a grande capacidade de generalização da GRNN, aliada ao seu treinamento em um único passo, torna-se ideal para a aplicação,

facilitando a inclusão de novos padrões de alarmes, a modificação dos padrões existentes, e a expansão para outros elementos pertencentes ao sistema elétrico.

7 Referências Bibliográficas

- Biondi Neto, L. Sistema Híbrido de Apoio à Decisão para Detecção e Diagnóstico de Falhas em Redes Elétricas. Rio de Janeiro, 1997. 203p. *Dissertação (Mestrado em Engenharia Elétrica)* – Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 1997.
- Cardoso Jr., G. Estimação da Seção em Falta em Sistemas Elétricos de Potência via Redes Neurais e Sistemas Especialistas Realizada em Nível de Centro de Controle. Florianópolis, 2003. 176p. *Tese (Doutorado em Engenharia Elétrica)*, Universidade Federal de Santa Catarina, Florianópolis, 2003.
- Frost, F. & Karri, V., Performance Comparison of BP and GRNN Models of the Neural Network Paradigm Using a Practical Industrial Application. *6th International Conference on Neural Information Processing, Proceedings ICONIP 99*, Vol. 3, Nov., 1999, pp. 1069-1074.
- Fu, S. et al. An Expert System for On-Line Diagnosis of System Faults and Emergency Control to Prevent a Blackout. *IFAC Control of Power Plants and Power Systems – SIPOWER'95*, Cancun, Mexico, 1995, pp. 303-308.
- Kirschen, D. S. & Wollenberg, B. F., Intelligent Alarm Processing in Power Systems. *Proceedings of the IEEE*, Vol. 80, Nº 5, May, 1992, pp. 663-672.
- Krose, B. J. A. & Smagt, P. P. V. D. An Introduction to Neural Networks. University of Amsterdam, Amsterdam, 7th edition, Dec., 1995.
- Marquez, L. & Hill, T., Function Approximation Using Backpropagation and General Regression Neural Networks. *Proceedings of the Twenty-Sixth Hawaii International Conference on System Sciences*, Vol. IV, Jan., 1993, pp. 607-615.
- Schaedler, C. A. et al.. O. Redes Neurais. Unisinos, São Leopoldo, 2003.
- Specht, D. F., Probabilist Neural Networks for Classification, Mapping or Associative Memory. *Proc. IEEE International Conference on Neural networks*, Vol. 1, June, 1988, pp. 525-532.
- Specht, D. F., A General Regression Neural Network. *IEEE Transactions on Neural Networks*, Vol. 2, Nº 6 (Nov.), 1991, pp. 558-576.
- Vale, M. H. M. et al.. Sta – Alarm Processing System. *VIII Simpósio de Especialistas em Planejamento da Operação e Expansão Elétrica – VIII SEPOPE*, Brasília, DF, Maio, 2002.