

Abordagem Inteligente para Tratamento de Alarmes e Diagnóstico de Falhas em Sistemas Elétricos

A. Arnaud¹, R. Cunha¹, G. Vasconcelos¹, P. Adeodato¹, J. Genu² e B. Regueira²

{adrian, rodrigo, germano, paulo}@neurotech.com.br¹ - {jaimegenu, brunoregueira}@celpe.com.br²

Resumo - Frequentemente, falhas em sistemas elétricos produzem um fato conhecido como “avalanche de alarmes”, caracterizado por uma seqüência de alarmes associados a diversos equipamentos disparando em um curto intervalo de tempo. Nesse tipo de problema, o operador tem dificuldade em interpretar a situação e diagnosticar corretamente as causas da falha. Neste contexto, é proposto um sistema inteligente que utiliza Redes Neurais Artificiais para detectar e Árvores de Decisão para classificar falhas em sistemas elétricos. Além disso, o sistema utiliza Regras de Episódio para extrair conhecimento estratégico sobre o sistema. Experimentos realizados com alarmes da CELPE resultaram em 92,5% de acerto na classificação de falhas.

Palavras-chave - Árvores de Decisão, Diagnóstico de Falhas, Regras de Episódio, Redes Neurais Artificiais, Tratamento de Alarmes.

I. INTRODUÇÃO

Eventualmente, falhas em sistemas elétricos produzem um fato conhecido como “avalanche de alarmes”. Essa situação é caracterizada por uma seqüência de alarmes associados a diversos equipamentos disparando em um curto intervalo de tempo. Nesse tipo de problema, o operador tem dificuldade em interpretar a situação e diagnosticar corretamente as causas da falha.

Apesar da utilização de Sistemas Especialistas nesse tipo de problema, a experiência dos operadores e engenheiros tem sido utilizada como ferramenta principal para a análise de ocorrências. Dessa forma, o tempo gasto para se obter conclusões precisas sobre as causas das perturbações e suas conseqüências conduz, muitas vezes, a retardos inaceitáveis nos processos de restabelecimento do sistema elétrico.

Considerando todos esses fatores e o fato de que a identificação de falhas pode ser representada matematicamente como um problema típico de reconhecimento de padrões, é altamente desejável dispor de métodos rápidos e robustos para detectar alterações no sistema elétrico, de modo a aumentar a qualidade dos serviços de transmissão e distribuição de energia e a auxiliar operadores e gestores do sistema no planejamento e execução das ações.

Neste contexto, é proposto no presente trabalho um sistema inteligente que emprega, respectivamente, Redes Neurais Artificiais (ANN) [5] para detectar falhas e Árvores de Decisão (AD) [10] para classificar falhas em sistemas elétricos. Além disso, o sistema utiliza Regras de Episódio [9] para extrair informações intrínsecas da base de alarmes, visando a obter conhecimento estratégico sobre o sistema. Tais informações podem indicar associações não esperadas

entre equipamentos (i.e., interferências), bem como problemas de oxidação, mau-contato, etc.

O artigo está organizado da seguinte forma. A Seção 2.0 discute alguns trabalhos relacionados. A Seção 3.0 apresenta brevemente as três técnicas de Mineração de Dados utilizadas no sistema proposto. Em seguida, na Seção 4.0, um sistema inteligente para tratamento de alarmes e diagnóstico de falhas é proposto. Na Seção 5.0, os experimentos realizados com os alarmes da Companhia de Eletricidade de Pernambuco (CELPE) são discutidos. Finalmente, a Seção 6.0 apresenta as conclusões deste artigo.

II. TRABALHOS RELACIONADOS

Com o desenvolvimento cada vez mais intenso da tecnologia digital, a busca de novas técnicas para automação da análise de perturbações nos sistemas de transmissão e distribuição tem sido alvo de pesquisas importantes nos últimos 15 anos, sugerindo-se a utilização de Sistemas Especialistas para análise de eventos em subestações.

De maneira geral, os sistemas modernos de gerenciamento de energia possuem algum tipo de processamento de alarmes para alertar os operadores sobre os parâmetros do sistema elétrico que estão fora da faixa normal ou de alterações que possam afetar sua operação. Alguns artigos sugerem a utilização de Sistemas Especialistas Orientados a Objetos e também baseados em RNA para tratamento dos alarmes processados, provenientes dos sistemas de aquisição de dados remotos e enviados aos centros de controle [2] [3] [6].

A utilização cada vez maior pelas empresas de transmissão e distribuição de registradores digitais de perturbação (RDP) para capturar os distúrbios no sistema de potência, seja de forma “stand alone”, ou integrada aos relés digitais de proteção, veio a contribuir de forma decisiva para as análises de perturbações pós-falha por parte dos engenheiros de proteção. Essa prática, no entanto, consome um tempo relativamente grande devido ao alto número de registros capturados e que serão alvo da análise. Por este motivo, foi sugerido em [7] [8], um sistema especialista para automatizar parte da análise de perturbações no sistema elétrico de potência, a partir dos dados registrados pelos RDP. Tal sistema é baseado num conjunto de regras, levando em conta o conhecimento do especialista, assim como estudos prévios para simular os vários distúrbios causados por falhas no sistema elétrico.

Mais recentemente, foi proposta uma técnica que utiliza o Raciocínio Baseado em Regras juntamente com o

Raciocínio Baseado em Modelos para gerar regras genéricas que modelam problemas em linhas de transmissão [1]. Já em [14], foi desenvolvido um sistema que utiliza tanto Regras de Associação, inferidas automaticamente de bases de alarmes, quanto regras fornecidas por especialistas para auxiliar no diagnóstico de falhas.

Apesar da existência de exemplos da utilização de Sistemas Especialistas nesse tipo de problema, a experiência de operadores e engenheiros tem sido utilizada, na maioria dos casos, como ferramenta principal para a análise de ocorrências. Além disso, pouco tem sido demonstrado, na prática, como o uso efetivo dessas tecnologias pode produzir benefícios qualitativos e quantitativos na minimização de erros e aumento da qualidade da operação dos sistemas elétricos. Com o objetivo de preencher esta lacuna, neste artigo se propõe um sistema híbrido inteligente, construído a partir de Redes Neurais Artificiais e Árvores de Decisão para as operações de detecção e classificação de perturbações na rede elétrica.

III. MINERAÇÃO DE DADOS

Aplicações de técnicas para extração de conhecimento em bases de dados vêm crescendo nos últimos anos em vista da grande quantidade de dados armazenados à medida que os sistemas tornam-se cada vez mais automatizados. O volume de dados a ser trabalhado em uma organização supera largamente a capacidade do processamento humano e mecânico, exigindo ferramentas mais adequadas aos novos desafios. A ampliação da capacidade de processamento criou um cenário perfeito para a proliferação do uso da Mineração de Dados [Wit99] na resolução de problemas do mundo real.

A Mineração de Dados faz uso de técnicas de Inteligência Computacional tais como RNA, Estatística, Algoritmos Genéticos, Lógica Difusa/Nebulosa e Inteligência Artificial Simbólica para extrair informações válidas e não óbvias de grandes bases de dados, visando a minimizar os erros cometidos no processo decisório.

A seguir apresentamos uma breve descrição das três técnicas inteligentes utilizadas pelo sistema proposto neste artigo: Redes Neurais Artificiais, Árvores de Decisão e Regras de Episódio.

A. Redes Neurais Artificiais

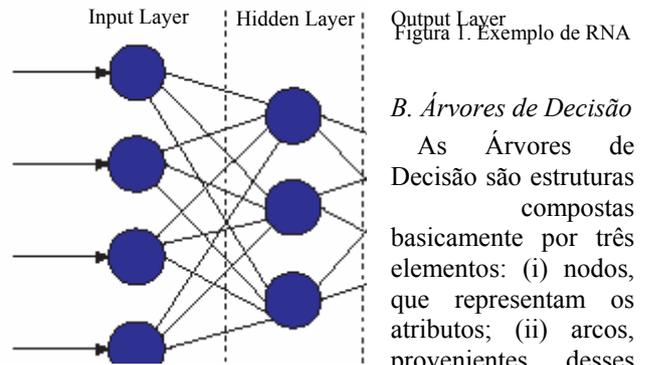
Segundo Haykin [5], uma Rede Neural Artificial (RNA) é um sistema de processamento paralelo e distribuído, constituído de unidades de processamento simples (os neurônios), interligadas entre si e com o ambiente através de conexões, e dispostas em camadas. Uma RNA é uma estrutura computacional que possui uma propensão natural para aprender a armazenar conhecimento derivado da experiência e torná-lo disponível para uso, quando recebe um estímulo de entrada.

As RNAs do tipo Perceptrons, com múltiplas camadas (redes MLP), treinadas com o algoritmo *backpropagation* [13] têm sido o modelo de RNA mais frequentemente utilizado em aplicações práticas de classificação de padrões. Sua simplicidade de operação e comprovado desempenho são as principais razões para tal popularidade. Este é o modelo de RNA empregado neste trabalho.

As unidades de uma RNA são organizadas em camadas e interligadas através de conexões ponderadas (sinapses). A Figura 1 apresenta a arquitetura básica de uma MLP. A

primeira camada, chamada *camada de entrada*, simplesmente propaga a informação para uma *camada intermediária* (ou camada escondida) que efetivamente realiza algum tipo de processamento. É possível que haja uma ou mais camadas intermediárias seguidas por uma *camada de saída*, de onde o resultado do processamento é obtido.

Dentre as características mais atraentes das RNA destacam-se a excelente capacidade de generalização, a simplicidade de operação, a capacidade de realizar aproximação universal de funções e o fato de as saídas das derem aproximar probabilidades *a posteriori* Bayesianas.



B. Árvores de Decisão

As Árvores de Decisão são estruturas compostas basicamente por três elementos: (i) nodos, que representam os atributos; (ii) arcos, provenientes desses

nodos e que correspondem aos possíveis valores dos atributos; (iii) e folhas, que representam as possíveis classes de padrões do conjunto de treinamento. Cada caminho - a partir da raiz até uma folha - corresponde a uma regra de classificação. Um exemplo de Árvore de Decisão é apresentado na Figura 2.

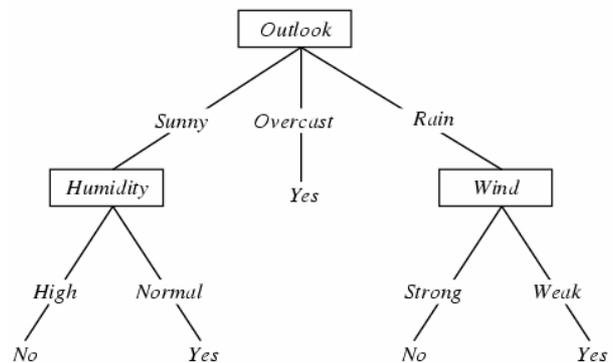


Figura 2. Exemplo de Árvore de Decisão

A indução de Árvores de Decisão é o processo para a geração do modelo de representação e solução de um problema. Um dos métodos típicos (empregado neste trabalho) consiste no uso do algoritmo ID3 [12] que define um caminho em árvore, de cima para baixo (“top-down”), com o objetivo de sempre escolher o melhor atributo para um nodo da árvore. A partir de um nodo raiz, o algoritmo particiona recursivamente os dados de treinamento – que são os representantes das classes de padrões - até que cada subconjunto de dados tenha exemplos de apenas uma classe. O resultado é a construção de um modelo que serve para classificar novos casos, percorrendo um caminho que se inicia na raiz e termina em uma folha.

Uma das vantagens das Árvores de Decisão é o fato destas produzirem regras de classificação da lógica proposicional, as quais são susceptíveis de compreensão por parte dos seres humanos.

C. Regras de Episódio

O problema fundamental aqui consiste em analisar uma seqüência de eventos com objetivo de encontrar os episódios freqüentes, isto é, conjuntos de eventos que ocorrem próximos de outros, a fim de mapear os relacionamentos entre eles [9].

Na seqüência mostrada na Figura 3, pode-se observar que todas as vezes que o Evento A e o Evento B ocorrem, o evento Z também ocorre em seguida.

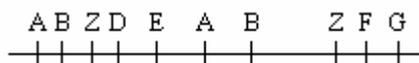


Figure 3. Exemplo de uma seqüência de alarmes.

Uma regra de episódio apresenta a probabilidade condicional que um certo evento (no nosso caso um alarme) ocorrer, em uma dada janela de tempo, dado um conjunto de alarmes [4]. O exemplo abaixo apresenta uma regra de episódio gerada a partir da figura 3.

Se Alarme A e B ocorrem, então um alarme Z ocorre dentro de 5 segundos com probabilidade de 100%

O objetivo de aplicar o algoritmo de regras de episódio neste trabalho é extrair conhecimento sobre as condições que levam os equipamentos a gerar uma seqüência de alarmes.

IV. SISTEMA PROPOSTO

O sistema proposto é formado por dois módulos principais. O primeiro, chamado de Sistema de Diagnóstico de Falhas (SDF), é responsável pela (i) sumarização de alarmes, (ii) detecção de falhas, dado por uma rede MLP com algoritmo de aprendizagem backpropagation (iii) ranking das causas mais prováveis que originaram falhas, dado por uma árvore de decisão, treinada com algoritmo ID3; e (iv) armazenamento dos alarmes em um formato específico, para ser utilizado posteriormente pelo segundo módulo do sistema.

A cada 10 segundos, o módulo SDF recebe um conjunto de alarmes SCADA e o associa a diagnósticos que indicam: equipamentos abertos, proteções atuadas, equipamentos dependentes, corrente interrompida e causas mais prováveis da falha (caso tenha havido). Abaixo, apresentamos um exemplo de diagnóstico:

04/02/2004 18:06:57	SPF_12V8	12BX A	ABERTO
04/02/2004 18:06:57	SPF_12V8	51N	ATUADO
04/02/2004 18:06:57	SPF_12Y2	12BX A	ABERTO
04/02/2004 18:06:57	SPF_12Y2	51N	ATUADO
04/02/2004 18:06:57	SPF_12Y2	86	NORMAL
04/02/2004 18:06:58	CPN_12Y3	50F	NORMAL
04/02/2004 18:06:59	PTO_SYS	Comm_Ucc	FALHA
04/02/2004 18:06:59	SPF_12V8	51N	NORMAL
04/02/2004 18:06:59	SPF_12Y2	51N	NORMAL

DIAGNÓSTICO

Abertura: SPF_12V8 e SPF_12Y2.

Proteções atuadas: 51N e 51N.

SE/SECC(s) dependente(s):

PDL, CPN, NZE, GLA, LME, BJD, SUB, JUC, CJO, RDB.

Corrente Interrompida:

245,14 A + 226,45 A = 471,59 A

Causas mais prováveis:

60% Árvore na Rede

40% Animais

Já o segundo módulo, o *Sistema de Extração de Conhecimento (SEC)*, é responsável pela geração de Regras de Episódio. Tais regras são geradas ao final do dia, a partir dos alarmes armazenados pelo módulo SDF. A regra abaixo indica interferência entre dois equipamentos:

Se PCOM_R3 = FALHA, então PCOM_R4 = FALHA. Ocorreu em 86% dos casos, com duração máxima de 10s, representando 0.3% da base.

V. RESULTADOS EXPERIMENTAIS

Visando a avaliar na prática a eficácia da solução desenvolvida, foram realizados diversos experimentos utilizando alarmes SCADA do sistema elétrico da Companhia Elétrica do Estado de Pernambuco (CELPE) equivalentes a dois anos de operação. Essa base de dados representa um conjunto com aproximadamente 3.500.000 alarmes.

Para treinamento e validação da MLP, foram utilizados 75% dos alarmes. O restante dos dados foi utilizado para teste. Para a indução da Árvore de Decisão, foi utilizado o método *10-fold cross-validation* [11] com todos os alarmes classificados como FALHA (aproximadamente 9.000 alarmes).

A Tabela I apresenta a matriz de confusão para as classificações geradas pela Árvore de Decisão, de modo a permitir uma melhor avaliação dos índices acerto obtidos com a solução desenvolvida. Cada linha da matriz representa as porcentagens das falhas reais classificadas pela Árvore de Decisão como pertencentes àquela classe (na diagonal da matriz estão as taxas corretas da classificação para cada classe).

TABELA I
MATRIZ DE CONFUSÃO

Classe Predita											Classe Verdadeira
A	B	C	D	E	F	G	H	I	J		
96.1	1.3	0.4	0.5	0.0	0.0	0.7	0.5	0.1	0.4	A	
1.9	93.4	0.4	0.4	0.2	0.6	0.9	0.2	0.4	1.5	B	
0.4	0.9	97.3	0.0	0.1	0.0	0.4	0.0	0.2	0.7	C	
2.1	1.8	0.2	92.8	0.3	0.3	0.2	1.3	0.0	1.1	D	
0.0	1.4	0.0	0.4	96.6	0.0	0.7	0.0	0.5	0.4	E	
0.2	2.4	0.2	0.2	0.0	95.1	0.2	0.0	0.0	1.8	F	
1.6	6.0	2.1	0.2	0.9	0.2	85.3	0.0	0.2	3.4	G	
1.9	1.1	0.6	1.7	0.0	0.0	0.0	94.2	0.0	0.6	H	
1.7	3.9	1.3	0.4	1.3	0.4	0.4	0.4	87.6	2.6	I	
0.8	2.1	0.9	0.3	0.2	0.8	1.1	0.3	0.4	93.2	J	

Em que A = Falha de isolamento; B = Em análise/Não localizada após análise; C = Árvore na rede; D = Falha em conexão; E = Abaloamento; F = Objeto na rede; G = Falha em equipamento; H = Falha em condutor; I = Manobras no sistema, e J = Outra.

De forma resumida, os resultados obtidos a partir do Sistema de Diagnóstico de Falhas foram os seguintes:

- 85,4% de redução da quantidade de alarmes gerados.
- 74,7% de acerto na detecção de falhas.
- 92,5% de acerto na classificação das falhas.

De forma resumida, os resultados obtidos a partir do Sistema de Extração de Conhecimento foram os seguintes:

- Identificação de inúmeros equipamentos para manutenção com regras geradas no período de 1 ano. Na sua maioria esses equipamentos possuíam problema de mau contato o que terminava ocasionando um conjunto de alarmes irrelevantes para o operador humano.

VI. CONCLUSÕES

Neste trabalho, foi desenvolvido um sistema inteligente que utiliza técnicas de mineração de dados para apoiar o operador humano em problemas de detecção, diagnóstico e prevenção de falhas em sistemas elétricos.

O sistema proposto é composto por dois módulos: Sistema de Diagnóstico de Falhas e Sistema de Extração Automática de Conhecimento. O primeiro sistema detecta e classifica possíveis ocorrências de falhas, enquanto o segundo módulo fornece uma base de conhecimento estratégico para melhor as circunstâncias de falhas em sistemas elétricos.

Os resultados obtidos com o sistema desenvolvido foram validados pelos operadores da CELPE e já produziram, em operação real, redução de perdas e custos, minimização de riscos e melhor otimização dos recursos da companhia.

Como trabalhos futuros, serão investigadas outras técnicas complementares de inteligência artificial e de tratamento de dados, com o intuito de melhorar ainda mais o desempenho das tarefas de detecção e classificação.

VII. REFERÊNCIAS BIBLIOGRÁFICAS

- [1] A. Duarte, "Desenvolvimento de uma Ferramenta de Tratamento de Eventos em Redes Elétricas", V SIMPASE, Recife, PE, 2003.
- [2] K. Hasan, B. Ramsay, and I. Moyes, "Object Oriented Expert Systems for Real-Time Power System Alarm Processing. Part I. Selection of a Toolkit", Electric Power System Research, 1994.
- [3] K. Hasan, B. Ramsay, and I. Moyes, "Object Oriented Expert Systems for Real-Time Power System Alarm Processing. Part II. Application of a Toolkit", Electric Power System Research, 1994.
- [4] K. Hätönen, M. Klemettinen, H. Mannila, P. Ronkainen and H. Toivonen, "Rule Discovery in Alarm Databases". Report C-1996-7, Department of Computer Science, University of Helsinki, March, 1996.
- [5] HAYKIN, S., *Neural Networks: A Comprehensive Foundation*, 2nd Edition, Prentice Hall, 1998.
- [6] M. Kezunovic, "Implementation Framework of an Expert System for Fault Analysis", Third Symposium on Expert System Applications to Power Systems, Tokyo, 1991.
- [7] M. Kezunovic, I. Rikalo, C. Fromen and D. Sevcik, "Expert System Reasoning Streamlines Disturbance Analysis", IEEE Computer Applications in Power, vol. 7, no. 2, pp. 15-19, 1994.
- [8] M. Kezunovic And I. Rikalo, "Advanced System Solutions for Automated Fault Analysis Using DFR Files", Precise Measurements in Power Systems and Fault Disturbance Analysis Conference, Arlington, 1996.
- [9] H. Mannila, H. Toivonen And A. Verkamo, "Discovery of Frequent Episodes in Event Sequences", Data Mining and Knowledge Discovery, pp. 259-289, 1997.
- [10] T. Mitchell, *Machine Learning*. McGraw-Hill, 1997.
- [11] F. Provost And T. Fawcett, "Robust classification systems for imprecise environments", In Proc. 15th Nat. Conf. on Artificial Intelligence, Menlo Park, CA, 1998.
- [12] J. Quinlan, "Induction of Decision Trees". *Machine Learning*, vol. 1, pp. 81-106, 1986.
- [13] D. Rumelhart, G. Hinton And R. William, "Learning Internal Representations by Error Propagation", *Parallel Distributed Processing*, vol. 1, MIT Press, Cambridge, pp. 318-362, 1986.
- [14] V. Silva, G. Ribeiro, R. Linden, L. Silva And C. Medeiros, "Sistemas Inteligentes Híbridos para Diagnose no COI da COSERN", VII STPC, Rio de Janeiro. 2003.