

METODOLOGIA PARA A MONITORAÇÃO DO PROCESSO DE DEGRADAÇÃO DE MEDIDORES ELETROMECCÂNICOS DE ENERGIA ELÉTRICA ATIVA

Marcelo R. Silva¹, Luigi G. Junior¹, Ediléu C. Junior², Márcio Sciamana², João O. P. Pinto³, Carlos A. Canesin¹

¹Universidade Estadual Paulista – UNESP
Laboratório de Eletrônica de Potência – Departamento de Engenharia Elétrica
Av. José Carlos Rossi, 1370, 15385-000, Ilha Solteira, SP, Brasil

²Elektro-Eletricidade e Serviços S.A.

³Universidade Federal de Mato Grosso do Sul
Cidade Universitária s/n, C.P. 549, CEP: 79.070-900, Campo Grande, MS, Brasil

e-mail: canesin@dee.feis.unesp.br

Resumo - Este artigo apresenta uma metodologia e um aplicativo para a análise da Probabilidade de Falha de medidores de energia elétrica ativa, tipo indução, considerando-se as principais variáveis correlacionadas com o processo de degradação destes medidores de energia elétrica, na área de concessão da Elektro. A modelagem desenvolvida para o cálculo da Probabilidade de Falha dos medidores foi implementada em uma ferramenta em plataforma amigável ao usuário, em linguagem Delphi, possibilitando não somente a análise das probabilidades de falha, mas também a classificação por faixas de risco, a localização no parque Elektro, e, permitindo, através de um sistema especialista, a amostragem de medidores de energia elétrica ativa, tipo indução, baseada em modelo de risco desenvolvido com inteligência artificial, com a finalidade principal de acompanhar e gerenciar o processo de degradação, manutenção e substituição destes medidores.

Palavras-Chave – Sistema especialista, Inteligência artificial, Medidores de energia elétrica ativa, Modelo de risco, Probabilidade de falha.

METHODOLOGY FOR THE MONITORATION OF THE DEGRADATION PROCESS OF ELECTROMECHANICAL ACTIVE ENERGY METERS

Abstract – This paper presents a methodology and software for hazard rate analysis of induction type watt-hour meters, considering the main variables related with the degradation process of these meters, for the Elektro Electricity and Services SA. The modeling developed to calculate the watt-hour meters hazard rate was implemented in a tool through a user friendly platform, in Delphi language, enabling not only hazard rate

analysis, but also a classification by risk range, localization of installation for the analyzed meters, and, allowing, through an expert system, the sampling of induction type watt-hour meters, based on the risk model developed with artificial intelligence, with the main goal of managing the process of degradation, maintenance and replacement of these meters.

Keywords – Expert system, Artificial intelligence, Induction type Watt-hour meters, Risk model, Hazard rate.

I. INTRODUÇÃO

Os medidores de energia elétrica ativa, baseados no princípio de indução, são os equipamentos em maior utilização no parque metrológico brasileiro. Segundo dados da ANEEL [1], em 2009, o parque de medição nacional era constituído de 92,61% de medidores eletromecânicos.

Os medidores eletromecânicos possuem uma vida útil econômica estimada em 25 anos [2], porém não existe na literatura estudos que determinem a vida útil metrológica dos medidores, isto é, estudos que apontem quantos anos os medidores conseguem medir corretamente a energia, dentro de sua classe de exatidão. A tabela 1 apresenta a distribuição de todos medidores (eletromecânicos e eletrônicos), no Brasil, por faixa de idade.

TABELA I

Distribuição de medidores de acordo com a faixa de idade

Faixa de idade	Frequência
Estoque	3,12%
0 a 5 anos	29,86%
6 a 10 anos	21,05%
11 a 15 anos	12,98%
16 a 20 anos	8,31%
21 a 25 anos	7,82%
+ de 25 anos	16,86%

O medidor de energia eletromecânico é um equipamento que pode ter seu funcionamento e precisão influenciados pelas seguintes características externas [2-8]:

¹Artigo submetido em 14/08/2010. Primeira revisão em 15/03/2011; segunda revisão em 18/06/2011. Aceito para publicação em 18/06/2011 para a Sessão Especial por recomendação do editor especial Antonio J. Marques Cardoso.

- Variações de temperatura ambiente: segundo [2], um aumento de temperatura de 10°C pode ocasionar uma redução de 4% de torque motor e redução de 5% de torque frenante;
- Variações da tensão da rede: sobre-tensões fazem com que o medidor indique um valor de consumo menor do que o real, já sub-tensões acarretam em medição superior ao valor real;
- Variações da frequência da rede: as pequenas variações de frequência não afetam o funcionamento do medidor, mas para frequências maiores que a nominal a rotação do elemento motor tende a diminuir e para frequências menores que a nominal a rotação do elemento motor tende a aumentar;
- Campos magnéticos externos: devido o princípio de funcionamento ser através da indução eletromagnética, campos magnéticos intensos podem causar erros de medição nos equipamentos;
- Distorções harmônicas: os medidores baseados no princípio de indução eletromagnética apresentam erros de medição perante distorções harmônicas, podendo estes chegar até 10% [6-8];

De acordo com [3], dois itens que podem gerar erros de medição no decorrer dos anos são as engrenagens e o freio magnético. Sob fricção excessiva o elemento móvel tende a girar de maneira mais lenta registrando medição inferior ao valor real. Caso o freio magnético diminua sua intensidade, o medidor tenderá a permanecer girando após diminuição de carga.

O mancal também é item que pode gerar erros no decorrer dos anos: o desgaste da peça aumenta a superfície de contato do elemento móvel aumentando o atrito e, consequentemente, indicando consumo menor que o real.

Com base no contexto anterior, é fundamental obter informações comportamentais dos medidores instalados no parque das concessionárias de energia elétrica, considerando-se a necessidade normativa de mantê-los instalados operando dentro dos limites permitidos de erros de medição. Segundo o INMETRO, órgão de normatização para medição, os equipamentos eletromecânicos classe de exatidão 2 (mais comuns), devem apresentar erro de medição inferior a 2%, quando se trata de equipamento novo ou após reforma, e 4% quando se trata de equipamento para inspeção metrológica.

Neste trabalho é proposta uma metodologia que estima a probabilidade de falha associada aos medidores de energia elétrica ativa, tipo indução, utilizando um banco de dados e ferramentas de inteligência artificial. Como os dados englobam equipamentos distintos, instalados em diversas condições climáticas, e submetidos aos mais variados tipos de carga, propõe-se agrupar os medidores em classes (clusters). Assim, a probabilidade de falha apresentada para cada equipamento de uma classe pode ser considerada a probabilidade média de falha de todos os equipamentos pertencentes à classe. Finalmente será apresentado o aplicativo desenvolvido em plataforma amigável para auxiliar as concessionárias de energia na visualização da probabilidade de falhas nas localidades do parque e equipamentos instalados, bem como auxiliar na criação de planos de inspeção e manutenção de equipamentos com erro de medição acima do máximo admissível.

A consideração de falha do equipamento, aqui abordada, distingue da existente na literatura ([9-10]) na qual falha representa o não funcionamento do equipamento. No trabalho, falha inclui o conceito da literatura, mas também agrega os equipamentos que possuem erros de medição acima dos limites estabelecidos pela concessionária, em função das normatizações e regulamentações da ANEEL – Agência Nacional de Energia Elétrica, ou, dos órgãos de fiscalização metrológica, para o estado de São Paulo: ARSESP – Agência Reguladora de Saneamento e Energia do Estado de São Paulo.

Inicialmente será apresentado o processo de descoberta das variáveis mais significativas para a composição da metodologia de agrupamento, depois será apresentada a metodologia de agrupamento e calculada a probabilidade de falha associada a cada grupo. Por último é apresentado o aplicativo desenvolvido.

II. METODOLOGIA

A análise da probabilidade de falha é uma técnica estatística simples. Ela indica para o usuário qual a tendência de comportamento de um objeto no tempo próximo ao da amostra. A probabilidade de falha é calculada de forma discreta dividindo a quantidade de equipamentos que apresentam falhas pela quantidade total de equipamentos. Esta é a probabilidade de falha média. A eficiência do modelo de análise de probabilidade de falha pode ser elevada através da segmentação dos medidores de energia em classes (clusters). A eficiência máxima ocorre quando forem criados apenas dois grupos: um onde nenhum equipamento apresenta falha e outro onde todo equipamento apresenta falha. Este seria um modelo que se ajusta perfeitamente aos dados, porém o modelo estaria ajustado a ruídos, não sendo recomendado.

A metodologia de agrupamento desenvolvida é baseada em uma ideologia simples. São analisadas informações de falha de medidores para algumas variáveis, como número de fases e modelo, determinando a probabilidade de falha para cada valor das variáveis. Para a construção da classe do medidor (agrupamento), se verifica os valores que ele assume em cada variável, somando-se os valores de probabilidade de falha que cada variável do equipamento assume. Para diminuir o número de classes, o valor final da soma é arredondado para o número inferior, múltiplo de dez, mais próximo.

Para análise da probabilidade e construção da metodologia foram utilizados dados do parque de medidores da Elektro Eletricidade e Serviços S/A. Os dados de ensaios dos medidores foram extraídos dos relatórios anuais que a concessionária enviou para a ARSESP no período de 2004 a 2007.

Para a metodologia devem ser utilizadas apenas as variáveis mais significativas para determinação de falhas nos medidores de energia elétrica ativa, tipo indução. A utilização de variáveis desnecessárias pode tornar o conhecimento obtido confuso ou levar a aprendizagem de ruído. É necessário eliminar somente variáveis desnecessárias, isto é, variáveis não-relacionadas com o conhecimento que se pretende atingir. Eliminação de dados está relacionada com eliminação de conhecimento.

A. Seleção das variáveis

Para se obter as variáveis mais significativas, se utiliza o processo de descoberta de conhecimento em base de dados (DCBD) [11-14]. Este visa obter conhecimento específico, a partir de grandes bases de dados. A Figura 1 apresenta o diagrama do processo.

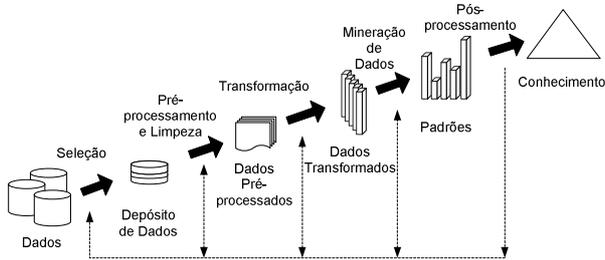


Fig. 1. Processo de Descoberta de Conhecimento em Base de Dados.

Duas tabelas da concessionária foram utilizadas no processo:

- *Uc_medidor*: contém dados históricos de instalações e retiradas de medidores de energia elétrica em unidades consumidoras.
- *Med_cons*: contém dados históricos de consumo mensal de unidades consumidoras.

Estas tabelas não contêm informação sobre falha dos equipamentos, sendo a informação obtida dos relatórios submetidos à ARSESP. Diversas variáveis relativas aos medidores, e o tempo médio de vida desses medidores foram selecionadas para DCBD, como: número de fases, ano de fabricação, modelo do medidor, consumo mensal médio da unidade consumidora (UC), precipitação anual média da localidade onde o medidor está instalado, altitude média da localidade, temperatura média anual das localidades, etc. Para complementar o elenco de variáveis que podem influenciar na degradação dos equipamentos foram inseridos dados climáticos obtidos no banco de dados climáticos do Brasil, mantido pela EMBRAPA (Empresa Brasileira de Pesquisa Agropecuária).

Visando a obtenção de dados consolidados para a aplicação de técnicas de mineração, os dados foram filtrados e aglutinados em uma única tabela denominada depósito de dados (ou dados alvos), a qual se tornou a referência para as demais etapas.

Os dados foram então sumarizados e receberam tratamentos estatísticos para eliminação de erros e utilização nas técnicas de Mineração de Dados, conforme descrito em [11]. Entre as tarefas de pré-processamento destaca-se a integração de dados e discretização [15]. O depósito de dados contém dados históricos dos medidores de energia, apresentados em registros. Esses dados possuem informações que não são diretamente obtidas, sendo necessária a integração dos dados. Reduziu-se a quantidade de registros existentes e obtiveram-se informações necessárias, tais como a quantidade de instalações que o medidor de energia teve no parque de medição e o consumo médio mensal do mesmo, considerando-se a UC na qual o medidor está ou esteve instalado, compreendendo para o cálculo do consumo médio mensal o período a partir da instalação do equipamento.

B. Técnicas de mineração de dados

As técnicas de mineração de dados são utilizadas para diversos propósitos: classificação, regressão, agrupamento, etc. Neste trabalho duas técnicas, regressão stepwise e árvores de decisão, são utilizadas para determinar as variáveis mais significativas na representação da saída: presença ou ausência de falha no medidor de energia elétrica.

Regressão stepwise é um algoritmo que utiliza a regressão linear com o método dos mínimos quadrados para determinar as variáveis mais significativas para determinação da saída. O algoritmo insere ou remove as variáveis de entrada de acordo com um critério de avaliação da variância da raiz quadrada do erro médio (RMSE), utilizando testes de hipóteses [16]. Somente uma ação (inserção ou remoção) pode ser realizada por etapa. Em cada nova etapa, o percentual de dados corretamente classificados pelo modelo é calculado. Quando a variável não está incluída no modelo é analisada a relevância de sua inserção; caso a variável faça parte do modelo é calculada a relevância de sua remoção. Para a variável ser inserida ou removida, ela deve satisfazer o critério do teste de hipótese.

O critério de parada é atingido quando o algoritmo não consegue satisfazer o critério do teste de hipótese para nenhuma inserção/remoção. Outro critério de parada pode ser a quantidade de iterações do algoritmo. As variáveis selecionadas por stepwise foram: *subtipo equip*, *contabil*, *instalacoes*, *dias_de_vida*, *cod_tipo_local*, *cod_localidade* e *cod_classe_principal*.

A árvore de decisão é uma forma de classificação dos dados. As variáveis são representadas por nós e de cada nó partem ramos. Cada ramo representa um valor da variável representada pelo nó superior do ramo. No último nó da árvore se encontra o valor da variável de saída.

Os algoritmos de indução permitem construir uma árvore de decisão de dimensão reduzida. O conceito de entropia é utilizado pelos algoritmos ID3 (Iterative Dichotomiser 3) e C4.5 de Ross Quinlan [14] para determinar o posicionamento das variáveis na árvore de decisão, movendo para os nós superiores as variáveis que apresentam maior ganho de informação. Para a árvore ser utilizada na determinação das variáveis mais significativas para a classificação da saída deve-se realizar uma poda na árvore. De uma forma simplificada, pode-se pensar que as variáveis dos nós superiores são mais significativas na representação da saída do que as variáveis dos nós inferiores. A árvore de decisão para o problema é apresentada na figura 2. Esta árvore classificou corretamente 64% dos casos de falhas.

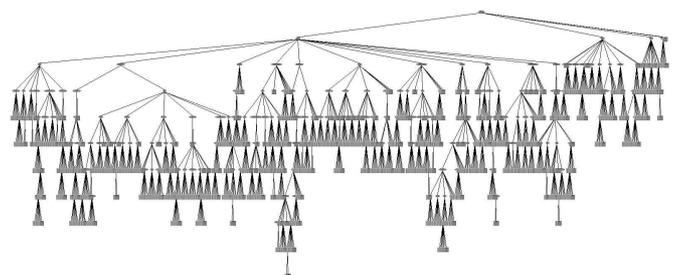


Fig. 2. Árvore de decisão para classificação de falhas.

No problema abordado utilizou-se a poda em nível, utilizando-se somente a variável do nó central e variáveis presentes em até dois níveis abaixo deste.

Utilizando somente as variáveis existentes após a poda a árvore passou a classificar corretamente 62,5% dos casos de falhas.

As variáveis selecionadas inicialmente foram aquelas selecionadas por todos os algoritmos de mineração de dados. O resultado foi uma classificação (via árvores de decisão) de 17,1% dos casos de falhas. O problema de determinação de falhas é visto como um problema de classificação, portanto foi dado mais importância às variáveis selecionadas pela técnica de árvores de decisão. Com a escolha adequada de algumas variáveis selecionadas somente pela árvore de decisão (após poda), se obteve um elenco de variáveis que classificam corretamente 61,1%. Essas variáveis são: modelo medidor, quantidade instalações, consumo médio, consumo máximo, dias de vida, tipo local, localidade, classe principal e precipitação média.

C. Construção do Modelo

As variáveis selecionadas por DCBD são as mais significativas para a construção de um modelo de risco capaz de segregar os medidores em classes que apresentam probabilidades de falhas dos equipamentos mais próximas do real do que a probabilidade de falha média.

Os medidores que apresentaram um desvio maior que $\pm 3\%$ nos conjuntos de ensaios padrão da concessionária, foram considerados inadequados ou “não OK”. A taxa de medidores “não OK” foi denominada de *score*. Abaixo são apresentadas as variáveis selecionadas para o modelo e suas descrições:

- Modelo medidor: o tempo de vida (em dias) do medidor na instalação atual;
- Quantidade instalações: quantidade de vezes que o medidor já foi instalado no parque de medição;
- Consumo médio: consumo médio mensal da instalação atual do equipamento;
- Consumo máximo: consumo máximo mensal da instalação atual do medidor;
- Dias de vida: período (em dias) em que o medidor está instalado;
- Tipo local: se o medidor está instalado em zona urbana ou rural;
- Localidade: município da UC;
- Classe principal: classe de acordo com res. 456 de 2000;
- Precipitação média: precipitação média mensal do município.

Para o cálculo da probabilidade de falha [19], as variáveis contínuas (consumo médio e máximo, dias de vida, e precipitação média) foram discretizadas [17-18]. As faixas foram determinadas buscando manter uma boa distribuição de equipamentos nas faixas.

O *score* de risco realiza a classificação dos medidores em classes, onde cada valor de *score* determina uma classe. O valor do *score* de risco é determinado através da soma da probabilidade de falha para cada variável selecionada, o valor final é sempre arredondado para a classe inferior

múltipla de 10. A tabela 2 apresenta um exemplo de determinação de *score* de risco (categoria).

A tabela 3 apresenta todas as classes definidas pela metodologia e a probabilidade de falha associada a cada classe.

TABELA II

Exemplo de cálculo de classe associada ao equipamento

Variável	Faixa	Score
Modelo medidor	PN5DG	11,71
Quantidade instalações	1	15,54
Consumo médio	0 <= valor < 100	14,92
Consumo máximo	0 <= valor < 150	16,36
Dias de vida	1600 <= valor < 2600	9,64
Tipo local	Urbano	13,92
Localidade	215	12,80
Classe principal	1	14,01
Precipitação	0 <= valor < 100	17,58
Classe		126,48 → 120

TABELA III

Classes e probabilidades de falhas associadas

Classe	Nº Casos	Probabilidade de Falha
70	10	0,00%
80	86	1,16%
90	375	1,87%
100	780	4,23%
110	934	5,35%
120	1453	8,33%
130	1323	14,74%
140	747	19,14%
150	581	32,01%
160	425	35,53%
170	224	40,63%
180	40	55,00%
190	8	75,00%
210	1	100,00%
220	4	100,00%

A probabilidade de falha associada a cada classe tende a se modificar com o tempo, isto ocorre porque a modelagem não é ideal. Para se ajustar os valores das probabilidades de falhas, novos dados de ensaios devem ser incorporados ao modelo. Porém, recalculando a probabilidade de falha para cada variável e realizando a reclassificação dos medidores gera um problema de agrupamento, uma vez que um novo grupo pode não conter os medidores previamente selecionados para o grupo. Outro ponto a se considerar são as classes onde não se obtiveram equipamentos de ensaio, mas em que é possível se obter casos do parque (e.g., classe 200).

Para contornar os dois problemas simultaneamente utiliza-se a regressão kernel, que define a nova probabilidade de falha para os pontos desejados, com base em pontos de memória. Esta ainda permite o uso de parâmetros de ajustes que definem qual a relevância dos novos dados para a definição das novas probabilidades de falhas.

III. FERRAMENTA EM PLATAFORMA AMIGÁVEL

A ferramenta foi desenvolvida em plataforma Delphi e banco de dados MySQL, sendo denominada WhFailure 1.0. O objetivo é fornecer um ambiente amigável com ferramentas desenvolvidas para a monitoração e gerenciamento da situação do parque de medição e fornecer um sistema para amostragem, por faixas de risco, para a identificação de equipamentos que estejam sujeito a elevadas

probabilidades de falhas. A figura 3 apresenta a interface principal da ferramenta.

Na figura 4 é apresentada a tela de importação de dados do parque de medição. Esta ferramenta permite importar imagens do parque para análise. Uma ferramenta semelhante permite importar dados de ensaios de equipamentos, para atualizar os valores de probabilidade de falhas, de acordo com a metodologia de inteligência artificial.



Fig. 3. Tela principal do aplicativo.

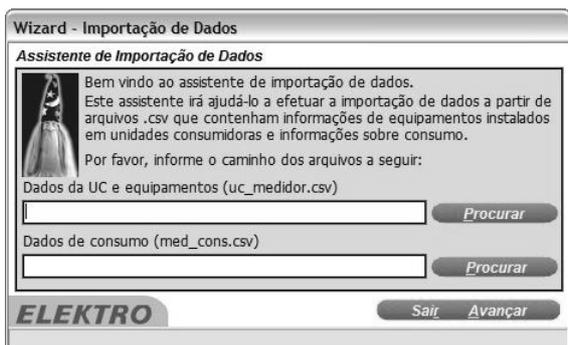


Fig. 4. Seção de importação de dados.

A ferramenta "Análise de Probabilidade de Falhas", apresenta uma interface para a realização de consultas para determinação da probabilidade de falhas, considerando a configuração de casos de análise (conjunto de medidores, Regionais, Consumo, Escalas de Probabilidades de Falhas, etc.), de acordo com o modelo de risco vigente. Nesta ferramenta é possível observar a estratificação da probabilidade de falhas encontrada para o caso em análise através de histogramas e tabelas, ou, a partir de recursos gráficos para localização espacial dos medidores de energia, englobados nos resultados em um mapa, contendo sua localização (cidade) e seu enquadramento na escala de probabilidade de falha. A figura 5 mostra a interface da tela de análise do parque de medição, considerando-se determinado modelo de risco, e, as decorrentes probabilidades de falhas. O mapa nas figuras 6 e 7 permite a visualização gráfica das classes de probabilidade de falhas encontradas, e as cidades onde os medidores estão instalados. A figura 6 apresenta uma visão geral do mapa, considerando um exemplo de caso. Adicionalmente, é possível através de um menu de controle de visualização alterar a escala e posição de visualização dos resultados, conforme mostra um

exemplo de Zoom aplicado ao mapa da figura 6, resultando no detalhamento da figura 7.

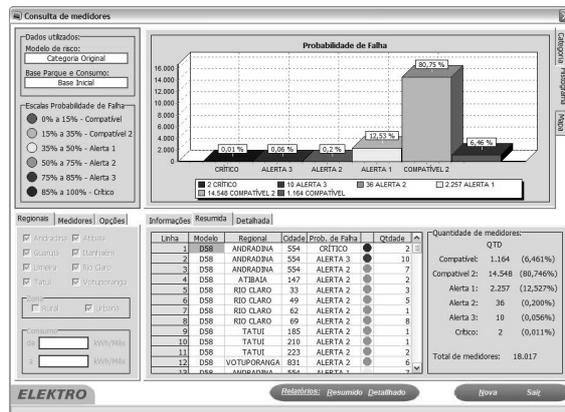


Fig. 5. Análise/Monitoramento do parque de medidores.

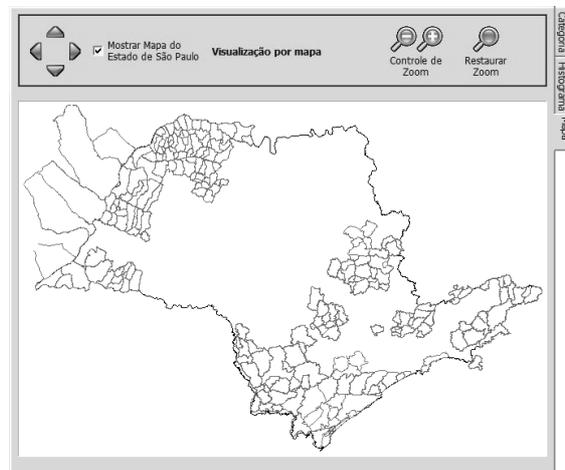


Fig. 6. Mapa da distribuição geográfica dos resultados obtidos.

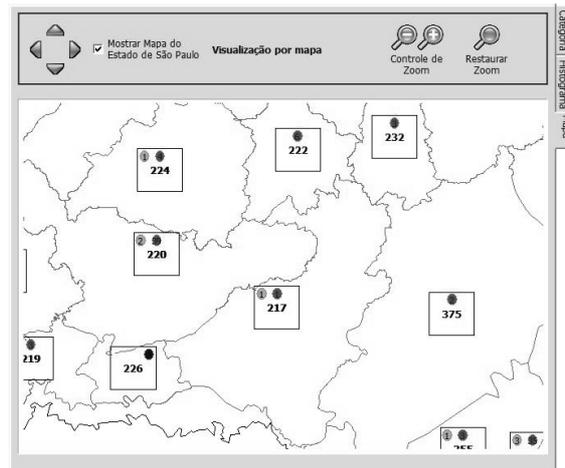


Fig. 7. Aplicação da ferramenta de zoom no mapa da distribuição geográfica dos resultados obtidos.

A segunda ferramenta denominada "Sistema Especialista" possibilita a realização de amostragens de medidores baseadas nos modelos de risco para simulação e predição da acurácia esperada para uma mesma amostragem em campo. A amostragem é oferecida através da geração de

relatórios que apresentam informações relativas à acurácia esperada para a amostragem realizada e localização atual dos equipamentos no parque de medição. A figura 8 apresenta a interface da ferramenta. A ferramenta distribui a amostra em dois tipos, aleatória e dirigida, sendo a segunda com uso da metodologia desenvolvida. São aceitos valores mínimo (20%) e máximo (50%) para a parcela aleatória, em relação ao tamanho total amostrado. A parcela de amostragem aleatória torna-se significativa à medida da necessidade de atualização do processo de degradação dos medidores nas diversas áreas de concessão da Elektro, para o refinamento das probabilidades de falhas. A figura 9 apresenta um exemplo de relatório obtido pela ferramenta de amostragem.

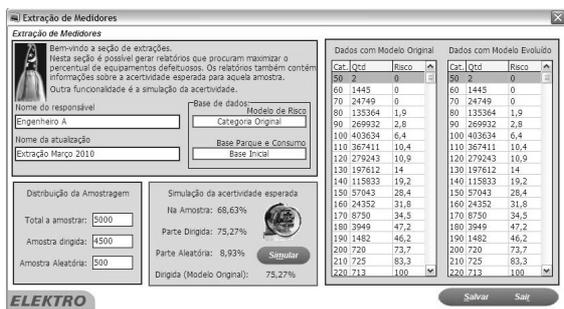


Fig. 8. Ferramenta especialista para realização de amostragens.

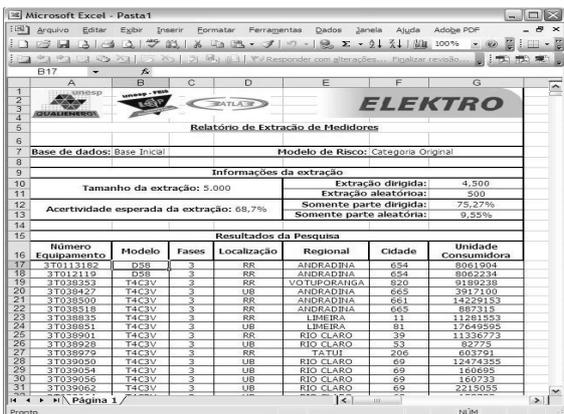


Fig. 9. Relatório para realização de amostragens.

A ferramenta "Configurações" possibilita o gerenciamento das bases de dados e das versões atualizadas de probabilidades de falhas, registradas e evoluídas através dos algoritmos de inteligência artificial. Através desta ferramenta são especificadas quais bases de dados e versão de probabilidade de falha para as classes estarão sendo consideradas na realização das análises e amostragens.

A probabilidade de falha pode ser atualizada através da importação de dados de ensaios, no padrão ARSESP. A figura 10 apresenta a interface de atualização de probabilidade de falhas. Os valores são atualizados com auxílio dos novos dados, importados previamente, sem descartar as informações da probabilidade de falha existente no modelo anterior, ou, original. O novo modelo de risco gerado pode ser salvo na base de dados principal, ou apenas ser visualizado. Este último modo é considerado como sendo apenas uma simulação para a verificação da tendência do

modelo de risco, considerando-se a atualização com a base de dados de ensaios em questão.

Conforme figura 10, após a obtenção do novo modelo de risco, o assistente de geração permite a simulação instantânea das evoluções possíveis do modelo de risco através da modificação de dois parâmetros empregados na técnica (Peso Inicial e Largura de Banda). Adicionalmente, as bases de dados escolhidas (Modelo de risco e Dados de Importação de Ensaio) são informadas na posição superior direita da tela do assistente. Caso seja necessário substituir a configuração das bases deve-se pressionar a opção "Voltar", e repetir o processo de seleção.

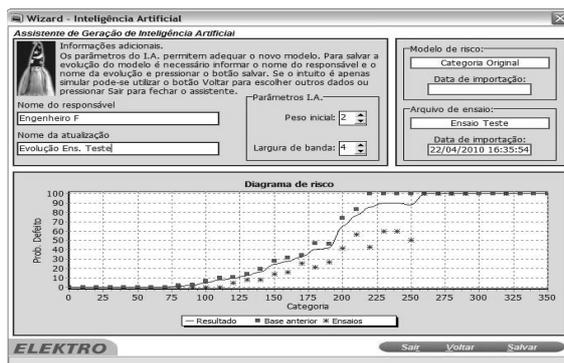


Fig. 10. Evolução do modelo de risco.

O Peso Inicial representa o quanto o modelo de risco original é importante em relação aos novos bancos de dados de ensaios que forem sendo inseridos. A possibilidade de aumentar a relevância dos dados iniciais é que eles foram obtidos com base em estudos estatísticos de toda a base de dados disponíveis sobre os medidores, enquanto os próximos dados de aprendizagem podem ser baseados em amostras. O peso inicial replica o modelo de risco original na memória, diminuindo o efeito dos novos dados inseridos.

Para garantir uma boa qualidade das estimativas é necessário ajustar a largura de banda. Para valores elevados de largura de banda a solução fica sobre-amortecida. Por isso a I.A. também possui o efeito de filtro, onde a frequência de corte está relacionada com a largura de banda da função Kernel. Para pequenas larguras de banda as estimativas se tornam ruidosas com grande variância. Embora isso gere alta precisão para os dados de treino, pode não haver boa precisão com os dados de parque.

IV. CONCLUSÃO

O aplicativo proposto permite um gerenciamento, até então inexistente, sobre a condição dos medidores de energia elétrica ativa, tipo indução, instalados no parque da Elektro, bem como um sistema especialista para a amostragem de medidores, auxiliando na elaboração de planos amostrais, com o objetivo de ampliar a acurácia nos processos de manutenção e/ou substituição de medidores de energia elétrica ativa, tipo indução.

A utilização de classes para determinação de probabilidade de falhas permite definir grupos de equipamentos com comportamentos semelhantes frente a falhas. Como o modelo não se ajusta otimamente ao modelo real, a técnica de regressão kernel garante que a

probabilidade de falhas das classes ocorra de forma progressiva, amortecendo ruídos existentes nos dados anualizados de ensaios.

AGRADECIMENTOS

Os autores agradecem ao CNPq e à Elektro Eletricidade e Serviços S.A pelo suporte financeiro dado para o desenvolvimento deste trabalho

REFERÊNCIAS

- [1] Brasil. Agência Nacional de Energia Elétrica. *Nota Técnica nº 00132009-SRD/ANEEL*. [s.l.]. Disponível em: <<http://www.aneel.gov.br>>.
- [2] Brasil. Agência Nacional de Energia Elétrica. “Estudo de vida útil econômica e taxa de depreciação”. In: *Anexos da Audiência pública 012/2006*. Disponível em: <<http://www.aneel.gov.br>>.
- [3] S. Krug, *Aplicação do método de design macroergonômico no projeto de postos de trabalho: estudo de caso de posto de pré-calibração de medidores de energia monofásicos*. 2000. 194 f. Dissertação Mestrado, Universidade Federal do Rio Grande do Sul – UFRS, Porto Alegre, 2000.
- [4] R. Chambers. “Early diagnosis of tariff metering faults by a systematic analysis of main/check metering discrepancies”. in *Conf. of Metering and Tariffs for Energy Supply*, 9, p. 213-217, 1999.
- [5] Brasil. Associação Brasileira de Distribuidores de Energia Elétrica (ABRADEE). *CODI-07.02 - Padrões e especificações de aparelhos eletromecânicos de medição; CODI-07.06 - Procedimentos para recebimento de medidores novos; CODI-07.07 - Procedimentos para recuperação de medidores*.
- [6] R. Arseneau, P. Filipski. “Application of a three phase nonsinusoidal calibration system for testing energy and demand meters under simulated field conditions”. *IEEE Transactions on Power Delivery*, v. 3, n. 3, p. 874-879, Jul. 1988.
- [7] E. Makram, C. Wright, A. Girgis. “A harmonic analysis of the induction watt-hour meter's registration error”. *IEEE Transactions on Power Delivery*, v. 7, n. 3, p. 1080-1088, Jul. 1992.
- [8] M. Saied. “On the accuracy of watt-hour meters in nonsinusoidal environment”, *Industry Applications Society Annual Meeting*, v. 3, p. 2219-2225, 1995.
- [9] A. Fashandi, T. Umberg. “Equipment failure definition: a prerequisite for reliability test and validation”, in *IEEE/CPMT International Electronics Manufacturing Technology Symposium (IEMT)*, 28, p. 357-358, 2003.
- [10] R. Misra. “Reliability assessment for static electricity meters”, in *Metering and Tariffs for Energy Supply*, 9, p. 151-155, 1999.
- [11] U. Fayyad, G. Piatetsky-shapiro, P. Smyth. “From data mining to knowledge discovery in databases”. *AI magazine*, [s.l.], v. 17, p. 37-54, 1996.
- [12] O. Maimon, L. Rokach, *The data mining and knowledge Discovery handbook*. Springer, USA, 2005.
- [13] G. Piatetsky-shapiro, G. Parker, *Data mining course*. [s.l.;s.n.]. Disponível em:

<http://www.kdnuggets.com/data_mining_course>. Acesso em 16 abr. 2010.

- [14] P. Adriaans, D. Zantinge, *Data mining*. Addison-Wesley, Boston, 1997.
- [15] M. Lenzerini. “Data integration: a theoretical perspective”, in *Proc. of Symposium of Principles of Database Systems*, 21, p. 223-246, 2002.
- [16] R. Fisher. *Statistical Methods for Research Workers*. Hafner, 25ª Edição, Nova Iorque, 1975.
- [17] U. Fayyad, K. Irani, “On the handling of continuous-valued attributes in decision tree generation”. *Machine Learning*. [s.l.], v. 8, n. 1, p. 87-102, Jan. 2005.
- [18] J. Schmitt. *Pré-processamento para a mineração de dados: uso da análise de componentes principais com escalonamento ótimo*. Universidade Federal de Santa Catarina - UFSC, Florianópolis, 147 f., 2005.
- [19] D. Rumelhart, G. Hilton, R. Williams. “Learning internal representations by error propagation”. *Parallel Distributed Processing: explorations in the microstructure of cognition*, v. 1, n. 2, 1986.

DADOS BIOGRÁFICOS

Marcelo Rubia da Silva, nascido em 1985 na cidade de Piracicaba (SP), é engenheiro electricista (2008) pela Universidade Estadual Paulista (UNESP) – Faculdade de Engenharia de Ilha Solteira (FEIS), Ilha Solteira (SP), e mestre formado na mesma instituição. Atualmente é colaborador da empresa Varixx Indústria Eletrônica LTDA, em Piracicaba (SP). Suas áreas de interesse incluem mineração de dados, sistemas inteligentes, medição e qualidade de energia elétrica.

Luigi Galotto Junior, nascido em 1981 em São Paulo (SP), é engenheiro electricista (2003) e mestre em aplicações de inteligência artificial (2006) pela Universidade Federal de Mato Grosso do Sul. Tem trabalhado como pesquisador desde 2003 e, atualmente, é professor colaborador na Universidade Federal de Mato Grosso do Sul. Me. Galotto tem a maior parte das publicações em congressos de eletrônica de potência do IEEE e publicações em monitoramento e diagnóstico.

Ediléu H. Cardoso Junior, nascido em Presidente Prudente (SP) em 1986, é engenheiro electricista (2008) pela Universidade de São Paulo - USP, em São Carlos (SP).

Atualmente trabalha como engenheiro na área de Medição, Perdas e Tecnologia da concessionária de distribuição de energia ELEKTRO - Eletricidade e Serviços S.A., em Campinas (SP), onde atua no desenvolvimento de projetos de telegestão de clientes Grupo A e B, gestão do parque de medidores e automação. Suas áreas de interesse incluem medição de energia, projetos de automação e inovação tecnológica (Smart Metering, Smart Grid).

Marcio Sciamana, nascido em Rio Claro (SP) em 1973, é engenheiro eletricitista (1997) pelo Centro Universitário Salesiano - UNISAL, em Americana (SP).

Atualmente trabalha como engenheiro sênior na área de Medição de Energia Elétrica da concessionária de energia ELEKTRO - Eletricidade e Serviços S.A., em Campinas (SP), onde vem trabalhando no desenvolvimento de projetos de sistemas de telemetria (automação da medição) e de sistemas de gestão e controle de perdas não-técnicas. Suas áreas de interesse incluem medição e qualidade de energia elétrica, automação de redes e subestações e projetos de inovação tecnológica (Smart Metering, Smart Grid).

João Onofre Pereira Pinto, nasceu em Valparaíso (SP), Brasil. Engenheiro Eletricitista pela Universidade Estadual Paulista, Ilha Solteira, Brasil, em 1990. Mestre em engenharia elétrica pela Universidade Federal de Uberlândia, Uberlândia, Brasil, em 1993, e Ph.D. pela The University of Tennessee, Knoxville, TN, EUA em 2001.

Atualmente é professor da Universidade Federal do Mato Grosso do Sul, Campo Grande, Brasil, onde ocupa o cargo de coordenador do programa pós-graduação em engenharia elétrica. Pesquisador do CNPq, suas áreas de interesse incluem mineração de dados, sistema de suporte a decisão, processamento de sinais, aplicações de redes neurais artificiais, lógica nebulosa, algoritmos genéticos e wavelets em eletrônica de potência, técnicas PWM, controle e acionamentos de máquinas elétricas.

Carlos Alberto Canesin, nascido em 1961, é engenheiro eletricitista (1984) pela Universidade Estadual Paulista (UNESP) – Faculdade de Engenharia de Ilha Solteira (FEIS), mestre (1990) e doutor (1996) em Engenharia Elétrica pela Universidade Federal de Santa Catarina (UFSC) – Instituto de Eletrônica de Potência (INEP), Florianópolis (SC).

Atualmente é professor titular do Departamento de Engenharia Elétrica (DEE) da UNESP-FEIS. Foi editor geral da Revista Eletrônica de Potência (gestão 2003-2004), ex-presidente da SOBRAEP – Sociedade Brasileira de Eletrônica de Potência (gestão 11/2004 – 10/2006). É editor associado da IEEE Transactions on Power Electronics. Suas áreas de interesse incluem qualidade da energia elétrica, técnicas de comutação não-dissipativa, conversores CC-CC, retificadores e inversores, fontes de alimentação chaveadas, reatores para iluminação e técnicas de correção ativa do fator de potência.