

Capítulo VIII

Sistema inteligente híbrido para detecção de perdas comerciais

Por Lucas de Faria, Antônio Padilha e Carlos Minussi*

As perdas de energia elétrica por furto, fraude ou erro na medição são denominadas “perdas não técnicas” ou “perdas comerciais”. A redução dessas perdas tem sido prioridade nas empresas concessionárias, bem como nos órgãos reguladores, tanto pelo seu crescimento nos últimos anos quanto pela sua atual dimensão. Furtos de energia elétrica realizados por consumidores ativos das classes residencial, comercial e industrial constituem o montante majoritário das perdas comerciais.

No Brasil, as perdas comerciais são altas por inúmeros fatores de cunho socioeconômico e cultural tais como: desemprego, baixa renda, falta de habitação, infraestrutura insuficiente, preço elevado da energia e de acessórios de ligação e impunidade em relação à corrupção e à fraude, por exemplo.

A fim de quantificar as perdas comerciais totais, as concessionárias idealmente deveriam realizar inspeções nos medidores de todas as Unidades Consumidoras (UCs), quantificar todas as ligações clandestinas, além de executar o levantamento da iluminação pública de toda a área selecionada. No entanto, devido ao grande número de UCs e ao alto custo das inspeções tal prática é inviável. Por isso, é preciso que o processo de identificação do perfil do consumidor seja automático. Nesse contexto, as concessionárias comumente optam por selecionar,

de maneira parcialmente automática, por meio de planilhas eletrônicas, alguns clientes cujo histórico de consumo mensal exiba comportamento anômalo. Tais clientes serão visitados pelas equipes de inspeção. Os parâmetros geralmente avaliados para cada cliente são a curva de consumo mensal e os dados cadastrais. No entanto, a curva de consumo mensal sofre diversas influências; logo, a análise de clientes a serem inspecionados não deve se basear unicamente pela avaliação da curva. Adicionalmente, os dados cadastrais, não raramente, contêm informações errôneas ou por estarem desatualizadas ou mesmo por erro no momento da realização do cadastro do cliente.

Portanto, os principais parâmetros comumente analisados para indicar se um determinado cliente é suspeito de ocasionar algum tipo de perda comercial estão longe de serem totalmente confiáveis. Isso confere um alto grau de complexidade ao problema de detecção de perdas comerciais no Sistema de Distribuição de Energia Elétrica (SDEE). Além das informações a respeito de cada consumidor não serem em quantidade suficiente, as existentes não são, em sua maioria, totalmente íntegras. Adicionalmente, o perfil dos clientes fraudadores é dinâmico, isto é, os fraudadores buscam mecanismos cada vez mais sofisticados para furtar energia a fim de não serem

descobertos.

A principal maneira de atuar no combate às perdas comerciais é a realização de inspeções nos pontos de consumo. Para aperfeiçoar o procedimento das inspeções, é preciso identificar previamente os consumidores que apresentam comportamento suspeito. Essa identificação é feita por um Sistema Baseado em Conhecimento (SBC) que automatiza o processo de seleção de clientes a serem inspecionados. Trata-se de um Sistema Inteligente Híbrido (SIH) intercomunicativo que combina, de forma independente, técnicas de Sistemas Inteligentes (SIs): redes neurais e lógica fuzzy. As redes neurais utilizadas são Perceptron Multicamadas (PMC) e os mapas auto-organizáveis de Kohonen (SOM – Self Organization Maps).

O objetivo é agilizar o processo de seleção de consumidores a serem inspecionados e aumentar a taxa de acertos de clientes com perdas comerciais de maneira a minorar o custo com inspeções.

Orientação das metodologias para estimação das perdas comerciais

Os trabalhos literários avaliados a respeito das perdas comerciais, de maneira geral, são orientados à detecção ou à estratificação das perdas comerciais em uma região. As metodologias orientadas à detecção (na qual se enquadra este trabalho) não se preocupam em explicar o que ocasiona as perdas comerciais, mas sim em localizá-las de maneira mais precisa e ágil possível. Em contrapartida, as metodologias orientadas às causas procuram fornecer uma estimativa a respeito das causas e quais são os tipos de perdas comerciais mais recorrentes em uma região específica.

As metodologias orientadas à localização são pontuais e objetivam encontrar, com a maior taxa de sucesso possível, as UCs com algum tipo de irregularidade. Para isso, valem-se de qualquer informação que, de alguma forma, aumente a taxa de sucesso das inspeções. Os dados de entrada mais usuais são: histórico de consumo mensal, dados cadastrais, atividade econômica, comentários dos inspetores e/ou leituristas, perdas globais no alimentador, denúncias, vulnerabilidade da região em que se encontra a UC, potência contratada, etc. Essas metodologias utilizam comumente ferramentas pertencentes à área de Sis, como redes neurais, lógica fuzzy, aprendizado de máquina, mineração de dados e de texto, etc.

Em contrapartida, o objetivo das metodologias orientadas às causas é fornecer um panorama geral a respeito das UCs de uma região. Em geral, utilizam apenas os dados colhidos em inspeções realizadas em UCs previamente selecionadas e, a partir dessas amostras, efetuam a extrapolação por meio de técnicas estatísticas e/ou probabilísticas. As principais ferramentas comumente utilizadas são técnicas estatísticas de amostragem, redes Bayesianas, Naive Bayes, etc.

Essas duas abordagens são complementares. As metodologias orientadas à localização possuem caráter determinístico e pontual,

consumo mensal com o objetivo de detectar fraudes e/ou anomalias a exemplo de trabalhos anteriores. Um diferencial dos atributos estatísticos em relação aos demais é que eles são mais intuitivos e, portanto, mais fáceis de serem analisados por um especialista.

Os 16 atributos estatísticos baseados na detecção de regimes da curva de consumo mensal foram adaptados. São eles: (1) N° de Regimes (NR – N° de Regimes ou Patamares da curva de consumo mensal do cliente); (2) Coeficiente de Variação (CV – representa a variabilidade do histórico de consumo mensal em relação à sua média. $CV = \text{Desvio Padrão} / \text{Média}$); (3) Percentual de Quedas em relação ao regime (PQ); (4) Percentual de Aumento em relação ao regime (PA); (5) N° de Quedas de regime (NQ); (6) N° de Aumentos de regime (NA); (7) Percentual de Tempo no Regime Inicial (PTRI); (8) Percentual de Tempo no Regime de Queda (PTRQ); (9) Percentual de Tempo no Regime Aumento (PTRA); (10) N° de Zeros (NZ – n°. de zeros da curva de consumo que corresponde aos meses cujo consumo é inferior a 10% do valor médio da curva de consumo); (11) N° de Regimes na Faixa Média (NRFM – define-se uma faixa em torno do valor médio da curva de consumo que corresponde a 10% da diferença entre as amplitudes máxima e mínima); (12) N° de Regimes Abaixo da Faixa Média (NRAbFM); (13) N° de Regimes Acima da Faixa Média (NRAcFM); (14) N° de Regimes na Faixa do Regime Inicial (NRFRI – define-se uma faixa em torno do regime inicial que corresponde a 10% da amplitude máxima); (15) N° de Regimes Abaixo da Faixa do Regime Inicial (NRAbFRI); e (16) N° de Regimes Acima da Faixa do Regime Inicial (NRAcFRI).

Módulo de agrupamento

Os clientes, neste módulo, são agrupados em classes ou clusters por meio do SOM. A cada agrupamento, associa-se um índice denominado GSA (Grau de Suspeita do Agrupamento) que o identifica. O GSA representa o risco de os clientes pertencentes a um dado agrupamento possuírem um histórico de consumo anômalo. Esse índice varia entre [0,1].

Os principais parâmetros do SOM são: aprendizado competitivo, treinamento não supervisionado, arquitetura neural reticulada, bidimensional 6 x 6 e aprendizagem online.

A redução do número de variáveis é útil ao cálculo do GSA e à redução do número de entradas da rede PMC (Módulo de Classificação). Os atributos NR, CV e NZ são mantidos. A eles são adicionadas outras cinco novas variáveis criadas a partir dos 13 atributos restantes conforme (1), (2), (3), (4) e (5). São elas: Percentual de Queda e Aumento de Regime (PQAR); N° de Queda e Aumento de Regime (NQAR); Percentual de Tempo em regimes de Queda e Aumento (PTQA); Regimes na Faixa Média (RFM); Regimes na Faixa do regime Inicial (RFI). Quanto mais positivas forem as cinco variáveis recém-criadas, maior é a tendência de redução do consumo ao longo do tempo. E quanto maiores forem as três variáveis restantes (NR, CV e NZ), mais atípico e anormal é o perfil de consumo do cliente.

$$PQAR = PQ - PA \quad (1)$$

$$NQAR = NQ - NA \quad (2)$$

$$PTQA = PTRQ - (PTRI + PTR A) \quad (3)$$

$$RFM = NRAbFM - (NRFM + NRAcFM) \quad (4)$$

$$RFI = NRAbFM - (NRFI + NRAcFRI) \quad (5)$$

A fim de obter o GSA, calcula-se o valor máximo de cada uma das oito variáveis para cada agrupamento. Aquele que possuir a maior quantidade de variáveis com valores máximos possuirá também o maior GSA. Portanto, um agrupamento cujo GSA é alto, possivelmente é constituído por clientes cujo perfil de consumo é atípico e/ou nos quais há uma tendência de redução do consumo de energia ao longo do tempo.

Módulo de classificação

Este módulo utiliza a rede neural PMC para realizar classificação dos clientes em duas classes: clientes com perfil de consumo normal e com perfil de consumo anômalo. Um problema de classificação de padrões consiste em associar um padrão de entrada a uma classe previamente definida. Este módulo recebe como entrada as oito variáveis normalizadas produzidas pelo módulo de agrupamento e possui saída binária.

A partir do histórico de inspeções obtêm-se o histórico de consumo mensal de clientes com perdas comerciais. A ele é adicionada uma porcentagem do histórico de consumo de clientes normais. Ao conjunto resultante denomina-se conjunto de treinamento e será utilizado para treinar a rede PMC. Dessa forma, a rede neural “aprende” quais são os perfis de consumo característicos de clientes anômalos, possivelmente ocasionadores de perdas comerciais.

As principais características da rede PMC são: treinamento supervisionado, on-line, via Backpropagation com Momentum. A rede neural PMC possui três camadas (8 – 20 – 2).

Módulo especialista

Este módulo consiste de um Sistema de Inferência Fuzzy (SIF) do tipo Mamdani implementado no Fuzzy Logic Toolbox 2, um aplicativo que compõe o MATLAB® 71 e que é dedicado ao desenvolvimento de SIFs Mamdani e TSK.

O objetivo deste módulo é modelar o conhecimento dos especialistas em perdas comerciais por meio de regras fuzzy. As variáveis de entrada são três atributos estatísticos extraídos do histórico de consumo mensal pelo módulo de extração de atributos estatísticos. São elas: o NZ, NR e o CV. Tais atributos foram escolhidos porque são mais intuitivos, mais fáceis de serem entendidos pelo especialista e por serem utilizadas na prática nas concessionárias, como o NZ, por exemplo. Ademais, outras variáveis de entrada podem ser facilmente adicionadas a este módulo. A variável de saída é o Índice de Suspeita do Especialista (ISE). Logo, a partir de regras simples envolvendo as variáveis de entrada e de saída,

espera-se identificar históricos de consumo atípicos possivelmente resultantes de clientes com perdas comerciais.

Neste módulo, constituído pelo SIF Mamdani, utilizam-se funções de pertinência triangulares e trapezoidais, inferência Max-Min e método de defuzificação centroide.

Módulo de busca

Os módulos anteriores analisaram exclusivamente desvios e anomalias no histórico de consumo mensal. Este módulo visa a ampliar a análise por meio da pesquisa no banco de dados por atributos adicionais tais como o IPCA e o ISA. Esses dois atributos não são pontuais, são por região, por área na qual estão os clientes em análise. Além do IPCA e do ISA, este módulo busca também características pontuais de cada cliente tais como o Consumo Irregular (CI) e o Religamento (R).

Outra busca interessante implementada neste módulo e não encontrada na literatura consultada refere-se à Lista de Nomes Suspeitos (LNS) e a Lista de Atividades Suspeitas (LAS). Informações como o nome completo e a atividade dos clientes flagrados em ilícitos durante inspeções em campo são armazenadas nas LNS e LAS. Posteriormente, durante a análise de cada cliente, é feita uma busca para averiguar se o sobrenome e a atividade de cada cliente constam nessas listas suspeitas. A presença do cliente na LNS e/ou na LAS não garante que ele pratique ilícito, mas é um indício a mais.

Módulo principal

Este módulo final pretende reunir todos os parâmetros obtidos nos módulos anteriores. A união dos parâmetros pontuais produz o Índice de Suspeita do Cliente (ISC).

Em (6), tem-se a expressão construída para obtenção do ISC. P1 pondera o parâmetro obtido a partir do módulo especialista (ISE); P2 pondera os parâmetros intrínsecos e não óbvios obtidos a partir das redes neurais SOM e PMC (módulos de agrupamento e de classificação, respectivamente) e, por último, P3 pondera os parâmetros obtidos a partir do módulo de busca. Esses pesos são arbitrados empiricamente pelo especialista conforme o seu julgamento acerca da confiabilidade dos dados de entrada.

Ao ISC são adicionados outros dois parâmetros: o ISA e o IPCA. Esses três atributos constituem as entradas deste módulo. Ele é constituído por um SIF cujos parâmetros são idênticos aos do módulo especialista. A saída deste módulo e da metodologia é o RPC (Risco de Perda Comercial) que é um índice no intervalo [0,1], o qual indica a possibilidade de um dado cliente possuir perda comercial.

$$ISC = \frac{P_1 ISE + P_2 \left(\frac{GSA + PMC}{2} \right) + P_3 \left(\frac{LNS + LAS + CI + R}{4} \right)}{\sum_i^3 = 1 P_i} \quad (6)$$

Testes e resultados

As simulações foram executadas por classes de consumo e por alimentador. Cada um dos módulos da metodologia foi programado no MATLAB® 7. O banco de dados foi desenvolvido no sistema de gerenciamento de banco de dados Microsoft Office Access® 2010. Foram utilizados drivers ODBC para conectar o programa do MATLAB® 7 ao banco de dados. Os testes foram realizados em um processador AMD Athlon™ II Dual-Core M; 2,1 GHz e 3 GB de memória RAM.

Os dados completos reais do sistema de distribuição são: dados cadastrais, o histórico de consumo mensal e alguns dados técnicos adicionais como o alimentador da rede de distribuição a que pertence cada cliente. Tais dados pertencem a um município do interior do Estado de São Paulo. O histórico de inspeções, o IPCA e o ISA foram arbitrados coerentemente com o intuito de testar a metodologia proposta. As simulações e os testes apresentados foram realizados em clientes residenciais, comerciais e industriais os quais possuem a maior parte das perdas comerciais e nos quais sua detecção é mais dificultosa.

Construção do histórico de inspeções

Com o objetivo de testar a metodologia proposta, construíram-se históricos de inspeções. São compostos por cinco grupos distintos de clientes comumente encontrados em históricos de inspeções reais. Eles estão apresentados na Tabela 1. Nessa tabela, estão descritos os estados das variáveis de entrada para cada grupo. “B” significa baixo índice de suspeita, isto é, uma entrada que corresponde a um cliente normal e “A” significa alto índice de suspeita, isto é, uma entrada característica de um cliente com perda comercial. Os quatro primeiros grupos correspondem a clientes com alguma anormalidade e o último é composto por clientes normais.

O grupo 1 é composto por clientes suspeitos com extrema dificuldade para serem detectados. Isso porque todos os indicadores pontuais (que têm maior poder preditivo) são todos “B”. Mesmo esse grupo tendo todos os indicadores por área (que têm menor poder preditivo) do tipo “A”, não reduz a grande dificuldade de detectar os clientes vinculados a ele. Possui características típicas de fraudes muito bem disfarçadas ou de novos loteamentos com fraudes embutidas já previamente instaladas. Para a maior parte das referências consultadas, os clientes deste grupo certamente seriam considerados totalmente normais.

O grupo 2 é constituído de clientes suspeitos cuja detecção é muito difícil. Dados Cadastrais “A” indica que o cliente possui um histórico de irregularidades e sabe-se que, em geral, os fraudadores são reincidentes e sempre buscam formas mais elaboradas de furtar energia a fim de não serem descobertos. No entanto, esse não é o caso dos clientes desse grupo, pois têm Dados Cadastrais “B”. Portanto, esse grupo é típico de clientes com medidor avariado que não têm intenção de lesar a distribuidora de energia.

O grupo 3 é formado por clientes suspeitos de difícil detecção e que são propensos a realizar fraudes – Dados Cadastrais “A”. No entanto, tais fraudes são muito bem camufladas, pois a fraude não causa grandes alterações no histórico de consumo mensal – Histórico de Consumo Mensal “B”.

O grupo 4 é o de mais fácil detecção. Possui clientes propensos a realizar fraudes e, provavelmente, já o fizeram anteriormente. Todos os indicadores pontuais são “A”.

E, finalmente, o grupo 5 é composto por clientes normais e cujos indicadores são todos “B”, exceto o IPCA que é “A”.

TABELA 1 – COMPOSIÇÃO DOS DADOS DE ENTRADA PARA CADA UM DOS CINCO GRUPOS QUE COMPÕEM O HISTÓRICO DE INSPEÇÕES

GRUPOS	INDICADORES PONTUAIS		INDICADORES POR ÁREA	
	DADOS CADASTRAIS	HISTÓRICO DE CONSUMO MENSAL	ÍNDICE DE PERDAS COMERCIAIS DO ALIMENTADOR (IPCA)	ÍNDICE DE SUSPEITA DA ÁREA (ISA)
1	B	B	A	A
2	B	A	A	B
3	A	B	A	B
4	A	A	A	B
5	B	B	A	B

Os históricos de inspeções arbitrados possuem a mesma proporção comumente encontrada em históricos de inspeções reais, isto é, para cada dez clientes, nove são normais (pertencem ao grupo 5) e um cliente possui alguma anormalidade (pertence a um dos demais grupos). Os históricos de inspeções serão utilizados em todas as simulações realizadas. Observa-se que o IPCA é igual a “A” em todos os grupos, porque, intuitivamente, os alimentadores com as maiores perdas são os primeiros a serem investigados.

Em suma, os cinco grupos possuem diferentes níveis de dificuldade de detecção. Pretende-se, portanto, avaliar o desempenho da metodologia proposta diante de cada um dos grupos criados.

Clientes residenciais

As simulações com clientes residenciais foram realizadas em 11.758 clientes pertencentes ao alimentador A5 da rede de distribuição. Cada um dos quatro grupos suspeitos (grupos 1, 2, 3 e 4) e o grupo de clientes normais (grupo 5) possuem 294 e 10.582 clientes, respectivamente.

Na Figura 2, tem-se o histograma com a distribuição do RPC para os grupos de clientes residenciais. A maior parte dos clientes dos grupos 1, 2, 3, 4 e 5 possuem RPC nos intervalos [0,2; 0,3], [0,4; 0,5], [0,6; 0,7], [0,9; 1,0] e [0,2; 0,3], respectivamente. Os grupos 1, 3, 4 e 5 possuem RPC satisfatório. Apenas o grupo 2 deveria ter um valor superior para o RPC, por ser composto de clientes anômalos.

Clientes comerciais

As simulações com clientes comerciais foram realizadas em 752 UCs pertencentes ao alimentador A5. Cada grupo suspeito e o grupo de clientes normais possuem 19 e 676 clientes, respectivamente.

Na Figura 3 tem-se o histograma com a distribuição do RPC para os grupos de clientes comerciais. A maior parte dos clientes dos grupos 1, 2, 3, 4 e 5 possuem RPC nos intervalos [0,1; 0,2], [0,2; 0,3], [0,3; 0,4], [0,4; 0,5], [0,5; 0,6], [0,6; 0,7], [0,7; 0,8], [0,8; 0,9] e [0,9; 1,0], respectivamente. Os grupos 1, 3, 4 e 5 possuem RPC satisfatório. Apenas o grupo 2 deveria ter um valor superior para o RPC por se tratar de um grupo de clientes anômalos.

Cientes industriais

As simulações com clientes industriais foram realizadas com 294 UCs pertencentes ao alimentador A5. Cada grupo suspeito e o grupo de clientes normais possuem 08 e 262 clientes, respectivamente.

A Figura 4 mostra o histograma com a distribuição do RPC para os grupos de clientes industriais. A maior parte dos clientes dos grupos 1, 2, 3, 4 e 5 possui RPC nos intervalos [0,2; 0,3], [0,3; 0,5], [0,7; 0,8], [0,9; 1,0] e [0,2; 0,4], respectivamente. Os grupos 1, 3, 4 e 5 possuem RPC satisfatório. Apenas o grupo 2 deveria ter um valor superior para o RPC porque ele é

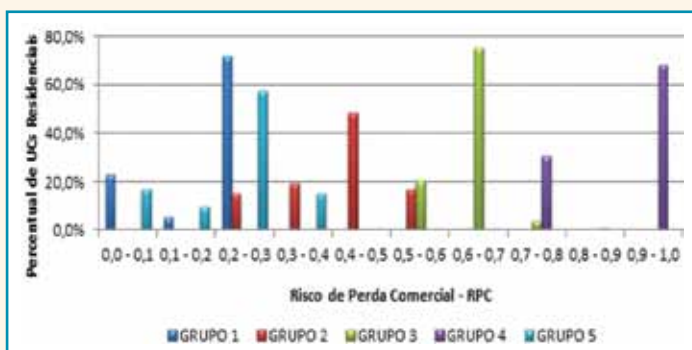


Figura 2 – RPC por intervalos para os grupos de clientes residenciais.

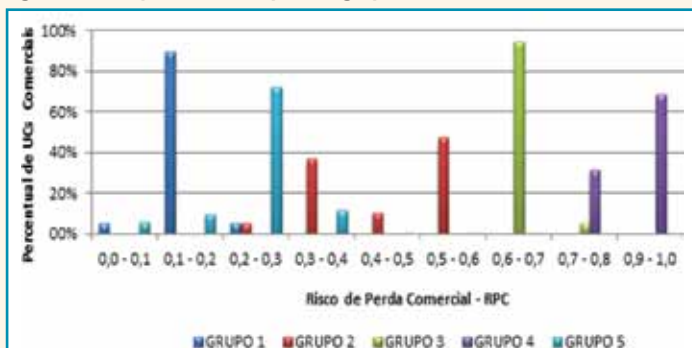


Figura 3 – RPC por intervalos para os grupos de clientes comerciais.

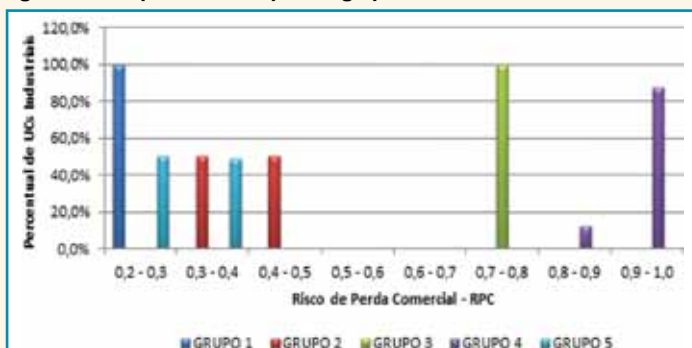


Figura 4 – RPC por intervalos para os grupos de clientes industriais.

composto por clientes anômalos. Os resultados das simulações mostraram-se satisfatórios diante das dificuldades, tais como:

- O histórico de consumo mensal dos clientes é muito homogêneo (típico de regiões com baixa incidência de perdas comerciais). A consequência é a redução da eficiência dos módulos de classificação, agrupamento e especialista.
- O módulo especialista e o módulo principal possuem uma base de conhecimento genérica, porque foram elaboradas sem a presença do especialista que conhece a fundo as particularidades do município de onde vieram os dados reais utilizados nas simulações.

Conclusões

Neste trabalho, criou-se um sistema computacional para detecção de perdas comerciais no SDEE. A principal contribuição foi o desenvolvimento de um sistema que se vale de todas as entradas que se têm disponíveis, bem como da união do conhecimento do especialista com informações intrínsecas obtidas via técnicas de extração automática de conhecimento oriundas da área de SI. Adicionalmente, são realizadas buscas na base de dados a respeito das perdas comerciais do alimentador e da vulnerabilidade da região em que se encontram os clientes em análise. Pretende-se, dessa forma, tornar o RPC o mais confiável possível, de modo a minimizar o gasto das concessionárias de energia com inspeções aos clientes suspeitos. A seguir, algumas considerações pertinentes a respeito do problema de perdas comerciais:

- Não se sabe com precisão quais são todas as regras que determinam um perfil suspeito. Nesse contexto, surge a necessidade de utilizar metodologias oriundas da área de SI a fim de descobrir relações ocultas entre os dados de entrada que possivelmente identifiquem um cliente com perdas comerciais.
- A base de regras é dinâmica e deve ser atualizada constantemente por meio, por exemplo, do conhecimento advindo das inspeções realizadas em campo.
- A metodologia apresentada possui um caráter empírico muito forte. Portanto, a habilidade e a experiência do especialista para elaboração das funções de pertinência, da base de regras e para calibração dos parâmetros é crucial para o seu funcionamento adequado.

Referências bibliográficas

- DANTAS, P. R. P. *Avaliação de perdas de energia elétrica não técnicas: metodologia aplicada no município de Salvador/BA. Dissertação de Mestrado, Departamento de engenharia e arquitetura, Universidade Salvador, Salvador, 2006.*
- FERREIRA, H. M. *Uso de ferramentas de aprendizado de máquina para prospecção de perdas comerciais em distribuição de energia elétrica. Dissertação de Mestrado, Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, 2008.*

- PENIN, C. A. S. *Combate, prevenção e otimização das perdas comerciais de energia elétrica. Tese de Doutorado, Escola Politécnica, Universidade de São Paulo, São Paulo, 2008.*
- o SMITH, T. B. *Electricity theft: a comparative analysis. Energy Policy*, v. 32. 2004, p. 2.067-2.076.
- CABRAL, J. E.; GONTIJO, E. M.; PINTO, J. O. P.; FILHO, J. R. *Fraud detection in electrical energy consumers using rough sets. In: Proceedings of the 2004 IEEE International Conference on Systems, Man and Cybernetics*, p. 3.625-3.629, 2004.
- JIANG, R.; TAGARIS, H.; LACHSZ, A.; JEFFREY, M. *Wavellet based feature extraction and multiple classifiers for electricity fraud detection. In: Transmission and Distribution Conference and Exhibition, 2002*, p. 2.251-2.256, v. 3.
- HAYKIN, S. *Redes neurais princípios e prática. 2. ed. Porto Alegre: Bookman, 2001.*
- o REZENDE, S. O. et al. *Sistemas inteligentes: fundamentos e aplicações. São Paulo: Barueri, 2005.*
- COMETTI, E. S.; VAREJÃO, F. M. *Melhoramentos na identificação de perdas não técnicas através da análise computacional inteligente do perfil de consumo e dos dados cadastrais de consumidores. Relatório técnico final do projeto de pesquisa e desenvolvimento, Vitória, 2005.*
- SILVA, N.; SPATTI, D. H.; FLAUZINO, R. A. *Redes neurais artificiais: para engenharias e ciências aplicadas. São Paulo: Artliber, 2010.*
- BASTOS, P. R. F. M. *Diagnóstico de perdas comerciais de energia elétrica na distribuição usando rede Bayesiana. Qualificação de*

Doutorado, Centro de Engenharia Elétrica e Informática, Universidade Federal de Campina Grande, Paraíba, 2011.

- GUERREIRO, J. I.; LEÓN, C.; BISCARRI, F. *Increasing the efficiency in non-technical losses detection in utility companies. MELECON 2010, 15th IEEE Mediterranean Electrotechnical Conference*, p. 136-141, 2010.
- NIZAR, A. H.; DONG, Z. Y.; ZHANG, P. *Detection rules for non-technical losses analysis in power utilities. IEEE Power and Energy Society General Meeting. Pittsburgh*, p. 1-8, 2008.

***LUCAS TELES DE FARIA é graduado em engenharia elétrica pela EEEC/UFG, em Redes de Comunicação pelo IFG-GO e obteve mestrado pela Feis/Unesp. Atualmente é doutorando pelo programa de pós-graduação em engenharia elétrica da Unesp, Ilha Solteira, SP.**

ANTÔNIO PADILHA FELTRIN é graduado em engenharia elétrica pela Unifei e obteve mestrado e doutorado pela Unicamp. Atualmente é professor titular do Departamento de Engenharia Elétrica da Unesp, Ilha Solteira, SP.

CARLOS ROBERTO MINUSSI é graduado em engenharia elétrica pela UFSM e obteve mestrado e doutorado pela UFSC. Atualmente é professor titular do Departamento de Engenharia Elétrica da Unesp, Ilha Solteira, SP.

Continua na próxima edição
Confira todos os artigos deste fascículo em
www.osetoreletrico.com.br
Dúvidas, sugestões e comentários podem ser encaminhados para o
e-mail redacao@atituedeeditorial.com.br