

INDICAÇÃO DE SUSPEITOS DE IRREGULARIDADE EM INSTALAÇÕES ELÉTRICAS DE BAIXA TENSÃO

Cyro Muniz, Karla Figueiredo, Marley Vellasco, Marco Pacheco, Gustavo Chavez

ICA: Inteligência Computacional Aplicada/DEE-PUC-Rio, Rua Marquês de S. Vicente 225, Gávea, Rio de Janeiro, CEP 22453-900, RJ Brasil

cyro@ele.puc-rio.br, karla@ele.puc-rio.br, marley@ele.puc-rio.br, marco@ele.puc-rio.br, gchavez@rdc.puc-rio.br

Resumo

O volume de perdas de energia elétrica sofridas pelas concessionárias no país, por questões de furto, erros de medida e demais tipos de irregularidades, tem-se intensificado nos últimos anos. Por este motivo, existe uma grande preocupação das empresas de energia elétrica em identificar o perfil de clientes irregulares com o intuito de reduzir este volume de perdas. Este artigo apresenta o desenvolvimento de um modelo, baseado em Redes Neurais, que tem por objetivo aumentar o grau de exatidão na identificação de irregularidades dentre os clientes de baixa tensão. O modelo utilizou dados da empresa Light S.A. e é composto por dois comitês de redes neurais artificiais, um para a filtragem da base de dados, e outro para a classificação efetiva dos clientes de baixa tensão. Os resultados obtidos mostram significativo aumento no percentual de clientes irregulares indicados corretamente como suspeitos pelo modelo proposto, em comparação com a metodologia atualmente utilizada pela companhia.

1 Introdução

As perdas comerciais de energia elétrica por irregularidades representam um prejuízo total para o país da ordem de R\$ 5 bilhões por ano. Essa energia representa cerca de 5% da energia total consumida no país. Grande parte dessas perdas ocorre na rede da empresa Light S.A., que atende a 3,8 milhões de unidades consumidoras em 28 municípios do Rio de Janeiro. Ressalta-se que o furto de energia tem impacto direto na tarifa paga pelos consumidores honestos. No cálculo do reajuste tarifário, feito anualmente, a ANEEL autoriza o repasse de parte das perdas com furtos para as contas de todos os consumidores. Nos cálculos da ANEEL, as contas de luz são até 17% mais caras, em alguns casos, unicamente em função do roubo e das fraudes de energia. Por isso é importante uma ação em conjunto de todos os setores envolvidos para tentar reduzir essas perdas [7]. Estes números denotam o quão importante e fundamental é o investimento de recursos nesta área.

A empresa Light S.A. identificou geograficamente as áreas onde há maior índice de perdas. Através deste mapeamento e de análises complementares, conclui-se que existe uma enorme relação entre o nível de perdas não técnicas da Light e as peculiaridades do Rio de Janeiro. Tanto o fato de que grande parte da população vive em favelas e em áreas da cidade consideradas de alto risco devido à violência, quanto a topografia da cidade, caracterizada pela presença de montanhas, cujas encostas têm sido progressivamente ocupadas de forma irregular pela população de baixo poder aquisitivo, dificultam sensivelmente a ação da Light no monitoramento do furto de energia.

O modelo de identificação de irregularidade atualmente praticado na empresa não se baseia em técnicas computacionais inteligentes para detecção de padrões de fraude, e sim em regras heurísticas em função da experiência de cada operador. Deste modo, o modelo utilizado atualmente é fortemente baseado na experiência do especialista e, portanto, bastante subjetivo. Este modelo atual é pautado em um conjunto de metodologias que identifica clientes de baixa tensão suspeitos de estarem cometendo algum tipo de irregularidade por um especialista da empresa que, com base em sua experiência, seleciona um determinado conjunto de clientes para serem inspecionados. Através deste processo, a Light tem obtido uma média de 25% de acerto na comprovação de clientes irregulares. Assim, verifica-se que o processo adotado é, ainda, ineficiente.

Diversos trabalhos já registraram as dificuldades deste tipo de investigação, como, por exemplo, a dificuldade em se avaliar os registros tidos como normais, os quais podem estar contaminados por irregularidades de medição que não foram detectadas durante a inspeção [12]. Dentre eles destacam-se [2][12][13]. Em [2] foram usados *Rough Sets* para o descobrimento de irregularidades de medição. Os resultados obtidos com esse modelo apresentaram baixa precisão (cerca de 20%) devido à presença de ruídos na base de dados da empresa cujos dados foram utilizados no estudo. Os trabalhos [12] e [13] abordam, de forma semelhante, o problema de classificação de irregularidades. Nestes dois trabalhos, foram usados somente consumos históricos. Como os consumos apresentam natureza temporal, nestes trabalhos foi necessária a aplicação de métodos de análise de séries temporais [10] para extrair novas características invariantes. Entretanto, outras variáveis relevantes, como informações sobre o instrumento de medição e a temperatura média não foram consideradas.

Este trabalho descreve o desenvolvimento de uma metodologia baseada em técnicas inteligentes cujo objetivo é aumentar o número de acertos na identificação de clientes de baixa tensão do tipo residencial que são irregulares, a partir de um conjunto de suspeitos selecionados. Neste trabalho foram usados outros atributos além do consumo, como temperatura, informações de irregularidades apontadas por leituristas ou detectadas no consumo. Também foram consideradas diversas métricas heurísticas inspiradas no atual procedimento de detecção de irregularidade utilizado pela Light. A compreensão do problema em toda a sua extensão, inclusive as peculiaridades sócio-econômicas do problema relacionado a perdas em baixa tensão são importantes, pois ajudam a identificar as características que devem ou não ser consideradas na metodologia e a conhecer as fronteiras de atuação do sistema inteligente a ser desenvolvido.

A metodologia para classificação de clientes desenvolvida nesse trabalho é realizada em duas etapas: *Filtragem* e *Classificação*, cada uma utilizando um comitê composto por cinco redes neurais artificiais. Cada um dos comitês realiza uma votação, seguindo a regra de Voto Majoritário Simples: se pelo menos três das cinco redes do comitê (ou seja, a maioria) identificar um cliente como suspeito, este será classificado pelo comitê como suspeito de ser irregular. O número de redes que indicaram a irregularidade permite avaliar a probabilidade de aquele cliente ser efetivamente irregular. Assim, o comitê fornece como resultado uma lista de clientes, classificados como suspeitos de serem irregulares, ordenados de forma decrescente pelas suas probabilidades de irregularidade. Dessa forma, os clientes suspeitos com maior probabilidade de possuir alguma irregularidade terão maior prioridade na lista de clientes a serem inspecionados. Como em toda metodologia baseada em comitês, o uso de um comitê de redes neurais tem por objetivo o aumento da exatidão ao produzir uma decisão consensual que é potencialmente mais exata que as redes neurais individuais [14] [16]. Os comitês são criados de forma a obter desempenhos complementares em diferentes regiões do espaço. Esta estratégia de uso de comitês é particularmente útil quando os membros do comitê são individualmente eficientes e cometem erros em diferentes regiões do espaço. Neste caso, os classificadores são denominados complementares [15]. No caso específico da Light S.A., essa complementaridade foi procurada dividindo-se a extensa base de dados disponível (mais de 15 mil registros, contendo todos os clientes de baixa tensão) em diferentes conjuntos de treinamento, um para cada membro do comitê, conforme será descrito na seção 3.

O restante deste artigo está organizado em mais quatro seções: a Seção 2 descreve a metodologia atual usada pela Light S.A. para detecção de irregularidades de consumo; a Seção 3 descreve a metodologia proposta, apresentando os dois comitês utilizados: Filtragem e Classificação; a Seção 4 apresenta os casos de estudo considerados; e, finalmente, a Seção 5 apresenta as conclusões do trabalho.

2 Metodologia atual para detecção de irregularidades de consumo

A empresa Light utiliza atualmente um conjunto de três metodologias de análise de consumo para selecionar clientes de baixa tensão que apresentem indícios de irregularidades, a saber: Variação Trimestral, Variação Anual e Fator de Ajuste.

As metodologias chamadas de Variação Trimestral e Variação Anual consistem, respectivamente, na comparação dos consumos dos 3 últimos meses e dos 12 últimos meses do cliente. A metodologia chamada Fator de Ajuste trata da comparação do consumo do último mês com o consumo do mesmo mês do ano anterior do cliente. Em todos estes casos, se a variação de consumo (Equação 1) for negativa e igual ou inferior a 30%, a instalação (o cliente) é indicada para uma verificação de campo (inspeção).

$$\text{variação} = \frac{\text{valor atual} - \text{valor anterior}}{\text{valor anterior}} \leq -0,3 \quad (1)$$

Todos os clientes que forem capturados por este conjunto de metodologias compõem uma base de dados da Light S.A. de clientes de baixa tensão suspeitos de irregularidades de consumo. Os clientes desta base de dados ainda passam por um especialista, que através de filtros construídos a partir de suas experiências e conhecimentos, seleciona um número específico de clientes a serem inspecionados por peritos da empresa.

Utilizando este conjunto de metodologias, a Light S.A. tem atingido um valor preditivo positivo (VPP) médio de 25%. O VPP (Equação 2) é a proporção de clientes comprovadamente irregulares entre todos os clientes que foram classificados como suspeitos de estarem cometendo alguma irregularidade. O VPP, portanto, expressa o percentual de clientes irregulares no conjunto de clientes suspeitos inspecionados.

A Tabela 1 apresenta uma matriz de confusão [11] típica para o caso de um problema de duas classes (por exemplo, clientes 'Normais' e 'Fraudadores/Irregulares'). Deste modo, de acordo com a Tabela 1, o valor preditivo positivo é dado pela Equação 2:

$$VPP = \frac{a}{(a + b)} \quad (2)$$

Tabela 1. Clientes Suspeitos x Clientes Inspeccionados

		Clientes Inspeccionados	
		Irregular	Normal
Indicação dos Clientes Suspeitos pelo Modelo Proposto	Fraudador/Irregular	a	b
	Normal	c	d

Em uma matriz de confusão (Tabela 1), os dados contidos nas células indicam o número de exemplos que possuem a referente classificação, sendo que as linhas indicam a classificação dada pelo modelo proposto, enquanto as colunas indicam os clientes inspeccionados/situação real. Por exemplo, para a matriz de confusão da Tabela 1, 'b' representa o número de clientes que o modelo classificou como 'Fraudador/Irregular', e que na base de casos reais de clientes inspeccionados estão classificados como 'Normal'. Seguindo este raciocínio, ao se observar as linhas da matriz de confusão tem-se:

- 'a' e 'b': indicam exemplos classificados pelo modelo proposto como 'Fraudador/Irregular';
- 'c' e 'd': indicam exemplos classificados pelo modelo proposto como 'Normal'.

Por outro lado, as colunas da matriz de confusão indicam a classificação realizada na inspeção:

- 'a' e 'c': indicam exemplos onde a classificação real é 'Fraudador/Irregular';
- 'b' e 'd': indicam exemplos onde a classificação real é 'Normal'.

3 Metodologia Proposta

A metodologia proposta neste trabalho é composta de três módulos básicos, chamados Pré-Processamento, Filtragem e Classificação. A Figura 1 apresenta essa metodologia, baseada em dois comitês de redes neurais para a identificação de clientes suspeitos de cometer fraude ou de apresentarem alguma irregularidade. A Figura 1 ilustra a metodologia completa utilizada durante a fase de aprendizado. Já a Figura 2 apresenta uma configuração mais simples usada na fase de recuperação da informação (*recall*), isto é, após a fase de treinamento, a qual não inclui o módulo de Filtragem.

O primeiro módulo, presente em ambas as fases, aprendizado (Figura 1) e *recall* (Figura 2), é denominado de Pré-Processamento e Normalização. Nesse módulo todos os atributos são selecionados, limpos e normalizados ou codificados. É importante destacar que a base de dados de inspeção é muito ruidosa, contendo informação com baixa confiabilidade devido a (intencional ou não) indicações incorretas do inspetor de clientes irregulares como normais. Também existem casos de campanhas feitas pela empresa para inspecionar toda uma região, independentemente de haver ou não alguma suspeita de irregularidade ou fraude nessa região. O efeito das campanhas é a descoberta de irregularidades ou fraudes em clientes que não têm qualquer indício de irregularidade ou fraude. Assim, para criar uma base mais confiável para uso no módulo de Classificação, um módulo de Filtragem foi criado.

O Módulo de Filtragem, descrito na subseção 3.2, usa um comitê com cinco redes neurais, o qual irá selecionar consumidores Normais e Irregulares/Fraudadores que melhor caracterizem estas duas classes.

A base de dados resultante da filtragem é empregada no treinamento do Módulo de Classificação, o qual é o módulo que realmente indica um consumidor como Normal ou Irregular quando o sistema estiver completamente treinado. Por isso, as futuras classificações de clientes (fase de *recall*) irão conter apenas os módulos de pré-processamento e classificação. O Módulo de Filtragem somente é necessário quando o sistema precisar ser retreinado. Tanto na etapa de filtragem quanto na de classificação, cada rede neural que compõe o comitê é desenvolvida utilizando-se um conjunto de validação para determinar o número de processadores na camada escondida e o número adequado de ciclos de treinamento.

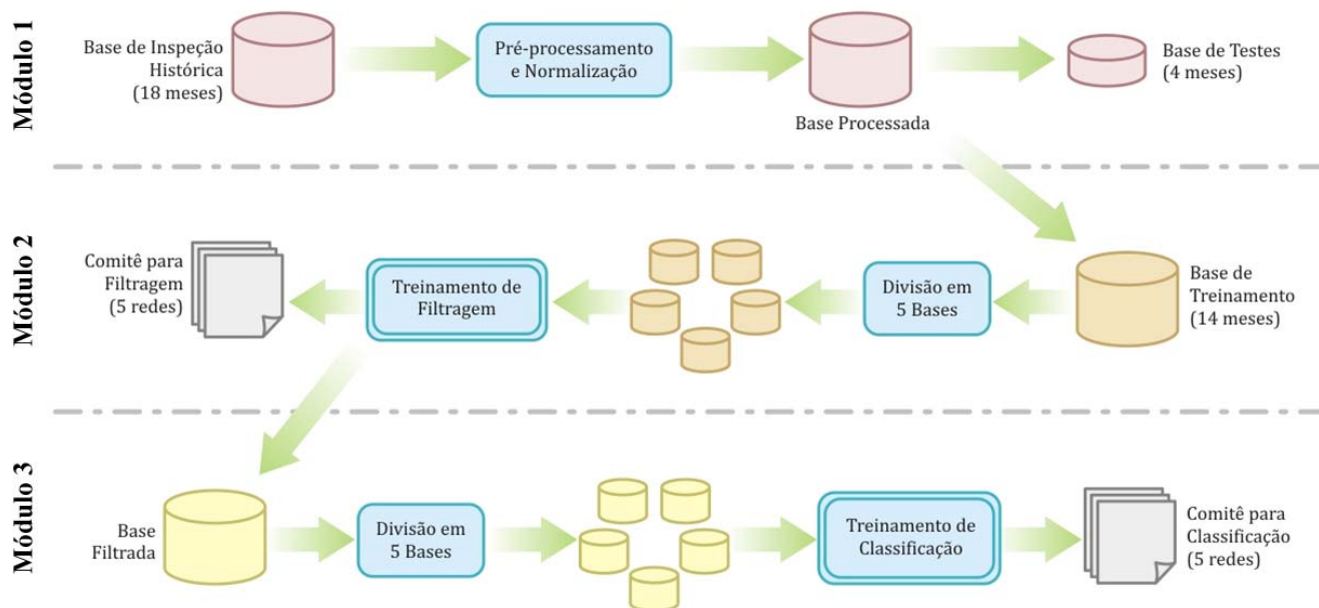


Figura 1 – Diagrama de blocos da Fase de Treinamento da metodologia proposta

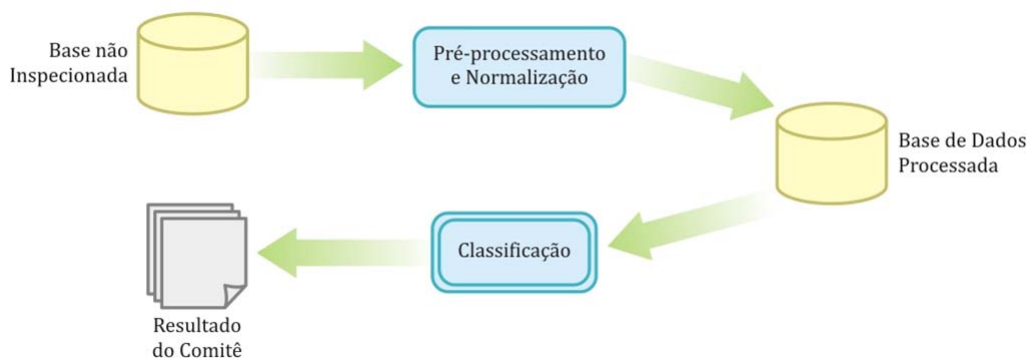


Figura 2 – Diagrama de blocos da metodologia proposta para a fase de Classificação (*Recall*)

As subseções seguintes apresentam em detalhes cada um dos módulos do modelo proposto para a identificação de clientes irregulares (com perdas comerciais).

3.1 Módulo 1: Pré-Processamento da Base de Dados

A etapa de pré-processamento é composta pelas seguintes fases: pré-seleção de atributos, limpeza de dados e normalização. Os dados utilizados neste trabalho foram fornecidos pela empresa Light S.A. e são originários de diversas bases de dados que contêm atributos gerais de todos os clientes de uma ZEI (Zona Elementar de Intervenção) da regional Leste e são apenas de clientes residenciais. A Light S.A. divide a cidade do Rio de Janeiro em cinco regionais geográficas. Cada regional, por sua vez, é subdividida em ZEIs, que também é uma subdivisão geográfica.

Este modelo foi desenvolvido a partir de uma base de dados com somente 18 meses, devido a problemas de extração das informações da base de dados da empresa. Originalmente foram feitos testes com base de dados de quatro anos de histórico [3] [9] com dois atributos adicionais (uma média móvel e o Fator de Tendência) que eram calculados a partir desse histórico.

Na fase de pré-seleção, após avaliação de todos os atributos das bases de dados da empresa, foram selecionados os atributos relacionados ao consumo dos clientes nos últimos 13 meses e alguns atributos que caracterizam a instalação feita na unidade consumidora. A Tabela 2 apresenta os atributos selecionados nesta fase.

Tabela 2. Atributos Selecionados da Base de Dados

Atributo	Descrição
Local	Código de identificação da unidade consumidora
Data Inspeção	Data da realização da Inspeção
Mês Referência	Mês utilizado como referência Mês anterior ao da realização da inspeção Ex: inspeção: 05/07/2006 mês referência: junho de 2006
Origem	Motivo principal que ocasionou a inspeção
Medidor	Identificador de modelo do medidor
MonoBiTri	Indica instalação mono, bi ou trifásica
Cód. Irregularidade de Consumo	Última irregularidade de consumo detectada
Cód. Irregularidade de Leitura	Última irregularidade constatada pelo leiturista
Consumo no mês	Consumo da unidade consumidora no mês de referência
Consumo no ano anterior	Consumo registrado um ano antes do mês de referência Ex: mês referência: junho de 2006 ano anterior: junho de 2005
Indicador de Fraude	Indica se o inspetor encontrou uma fraude, irregularidade ou normalidade

Os três primeiros atributos provenientes da base de dados identificam respectivamente a instalação na qual foi realizada a inspeção, a data da inspeção, e o mês utilizado como referência para a extração dos dados. Estes três atributos não são utilizados como entrada da rede neural, apenas estão presentes para identificar os registros. Os cinco atributos seguintes detalham aspectos técnicos da instalação e de comportamento do cliente, e são codificados da seguinte forma:

- Origem – 60 origens diferentes, que foram divididas em quatro classes, codificadas em duas entradas binárias. As quatro classes de origem existentes são:
 - 1. Inteligência: Combinação de informações extraídas da base.
 - 2. Sistema: Informações detectadas automaticamente pelo sistema da Light S.A.
 - 3. Denúncia: Denúncias feitas por outros clientes ou leituristas.
 - 4. Agrupamento: Inspeções realizadas sem suspeita prévia de irregularidade.

É importante destacar que os clientes que nunca foram inspecionados não fazem parte da base de dados de aprendizado do modelo, mas certamente fazem parte da base da empresa. Assim, um cliente que nunca foi inspecionado poderá ser submetido ao modelo de classificação tendo como origem o código Agrupamento.

- Medidor – 90 modelos de medidor, agrupados em seis classes, de acordo com o tipo do medidor (mecânico ou eletrônico), forma de leitura (direta ou indireta), e se estão ou não fora de linha (obsoletos). Essas seis classes são codificadas em três entradas binárias. As seis classes de medidor existentes são:
 - 1. MMD: Medidor mecânico de leitura direta
 - 2. OMMD: Medidor mecânico de leitura direta (obsoleto)
 - 3. MMI: Medidor mecânico de leitura indireta
 - 4. OMMI: Medidor mecânico de leitura indireta (obsoleto)
 - 5. MED: Medidor eletrônico
 - 6. OMED: Medidor eletrônico (obsoleto)
- MonoBiTri – como possui três classes diferentes, duas entradas binárias são necessárias para codificá-lo.
- Código de Irregularidade do Leiturista e Código de Irregularidade de Consumo – Esses atributos foram codificados de forma que, se em um cliente ocorreu algum tipo de irregularidade, o seu atributo apresentará o valor 1; caso contrário, conterá o valor 0.

Os dois atributos seguintes, Consumo no mês e Consumo no ano anterior, detalham o perfil de consumo do cliente, e foram normalizados conforme (3):

$$valor_{NORM} = \frac{v_{MAX} - valor}{v_{MAX} - v_{MIN}} \quad (3)$$

onde *valor* é o consumo a ser normalizado; $valor_{NORM}$ é o consumo já normalizado; v_{MAX} é o maior valor de consumo registrado para o cliente nos últimos 13 meses; e v_{MIN} é o menor valor de consumo registrado para o cliente nos últimos 13 meses.

O atributo Indicador de Fraude indica o resultado da inspeção realizada, indicando se no cliente foi encontrada uma irregularidade ou não. Este atributo foi utilizado como a saída (alvo) para o treinamento das redes neurais do comitê.

Além destes atributos, foram criados alguns indicadores com base nas metodologias utilizadas pela Light (apresentadas na Seção 2):

- Indicador Trimestral 1 - variação do consumo do último mês para o penúltimo mês.
- Indicador Trimestral 2 - variação do consumo do último mês para o antepenúltimo mês.
- Indicador Trimestral 3 - variação do consumo do penúltimo mês para o antepenúltimo mês.
- Indicador de Ajuste: variação entre o consumo do mês e consumo do mesmo mês do ano anterior.

Por fim, foram acrescentadas ao conjunto de atributos descritos acima as temperaturas ambientais mínimas e máximas do mês, referentes à região geográfica dos clientes, e também a carga consumida por todos os clientes da Light, no mês de referência.

Na etapa de Limpeza de Dados são eliminados dados duplicados ou corrompidos, e identificados dados com valores fora da faixa de valores esperados (*outliers*). As etapas de Codificação e Normalização visam a codificar atributos categóricos e transformar os valores utilizados para que tenham a mesma influência no processamento dos dados, respectivamente. Tais processos visam a tornar a base de dados inteligível para os processos subsequentes. Como resultado de todas estas etapas realizadas no Módulo 1, obtém-se uma base de dados validada, consistente e no formato adequado para o processo de filtragem.

No Módulo 1, uma parte dos dados foi extraída da base inicial para formar a base de testes do modelo. Ela é composta por 4 (quatro) meses, sendo dois meses de verão (fevereiro e março de 2006) e dois meses de inverno (julho e agosto de 2006), retirados da base inicial composta por clientes inspecionados durante 18 meses. Assim, apenas 14 meses foram usados efetivamente para o ajuste dos modelos.

3.2 Módulo 2: Filtragem de dados

Considerando a metodologia proposta para a criação do sistema inteligente para identificação de clientes irregulares (com perdas comerciais), apresentada na Figura 1, o módulo seguinte é a 'Filtragem de dados', que vem a ser uma etapa bastante importante do modelo, já que o número de clientes inspecionados pelas distribuidoras de energia elétrica é relativamente grande, com informações bastante ruidosas. Devido a inúmeros problemas possíveis na inspeção, clientes com perfis bastante distintos podem ser caracterizados como pertencentes à mesma categoria (normal, por exemplo). Portanto, mesmo com um adequado pré-processamento de seus dados, as bases de dados de clientes apresentam registros conflitantes em relação ao perfil do consumidor, os quais prejudicam o correto aprendizado do modelo de classificação, sendo por isso necessária uma filtragem da base de dados.

A 'Filtragem de dados' utiliza a técnica de Redes Neurais, que procuram aprender o comportamento de cada grupo de clientes, detectando e selecionando aqueles que melhor caracterizem os suspeitos de algum tipo de irregularidade e os normais, filtrando-os em uma nova base de dados com a ajuda de um comitê.

3.2.1 Construção da base de dados para a Filtragem

A partir da base de dados limpa, já separada por ZEIs, contendo os atributos de entrada numéricos, codificados e normalizados, constrói-se uma base de dados equilibrada para o treinamento do modelo de filtragem dos clientes

verdadeiramente Fraudadores/Irregulares e verdadeiramente Normais. Como a base de clientes Fraudadores (foi comprovada fraude nos medidores ou furto por ligações clandestinas) é normalmente muito menor que o número de casos Irregulares (foi comprovada irregularidade técnica), e Normais (nada foi comprovado), o número de registros de fraude foi o que balizou o tamanho da base para o aprendizado. Assim, para evitar que o processo de treinamento não se torne tendencioso, isto é, que a modelagem da rede só identifique as características de um conjunto de amostras, a quantidade de clientes Normais foi igual à soma de clientes Fraudadores e Irregulares (estas duas bases estão grupadas, porque apresentam características semelhantes no consumo).

A base de dados equilibrada é então dividida em 5 bases, sendo que cada uma é embaralhada e subdividida em 2 partes: Treinamento (75%) e Validação (25%). É importante destacar que as bases foram criadas sem repetição, isto é, são bases excludentes, sendo cada uma delas usada para efetuar o treinamento de uma das cinco redes que compõem o comitê.

3.2.2. Limiares para Filtragem

Com o objetivo de gerar cinco novas bases de dados mais consistentes e menos ruidosas, foram testados dois limiares (o Limiar de Filtragem e o Limiar de Comitê de Filtragem). O Limiar de Filtragem é produto da apresentação de cada base de treinamento a cada uma das cinco redes previamente treinadas. Foram feitos testes com 2 critérios de filtragem aplicados nos valores de saída das redes neurais:

- O primeiro critério utiliza um *Limiar de Filtragem* duplo (limiar superior e inferior), com a finalidade de eliminar os dados ruidosos e conflitantes. Nesse caso, os clientes que gerarem no neurônio de saída das redes valores acima do limiar superior, serão considerados irregulares, e clientes que gerarem no neurônio de saída das redes valores abaixo do limiar inferior serão considerados normais. O objetivo desse limiar duplo é descartar os clientes que geraram valores de saídas nas redes na faixa entre os limiares inferior e superior.
- O segundo critério utiliza um *Limiar de Filtragem* simples, com a finalidade de definir como clientes *Fraudadores/Irregulares* os que gerarem valores de saída das redes acima do limiar, e como Normais os que gerarem valores abaixo do limiar. Nesse caso, nenhum cliente é descartado nessa fase de filtragem.

A Figura 3 apresenta um esquemático do processo de filtragem da base de dados. Após o treinamento das cinco redes do comitê, cada uma treinada com uma das cinco bases descritas na Seção 3.2.1, essas mesmas cinco bases são apresentadas separadamente ao comitê, denominado Comitê de Filtragem, extraindo cinco novas bases de dados, de forma a tentar obter padrões mais característicos de cada uma das classes, Normal e Fraudador/Irregular. Para isso é necessária a utilização de um segundo limiar, chamado de Limiar do Comitê de Filtragem, o qual estabelece o número de votos que serão considerados para se declarar um cliente como suspeito de ser Fraudador/Irregular, conforme detalhado na próxima seção.

3.2.3 Construção da Nova base de Filtragem

Com os resultados da votação do Comitê de Filtragem se faz a comparação com os clientes inspecionados reais mediante uma matriz de confusão. A Matriz de Confusão (Figura 3) mostra o número de classificações previstas versus as classificações corretas. Basicamente, a matriz de confusão confronta os resultados realizados pelo Comitê de Filtragem com os resultados das inspeções reais nos clientes realizadas pelas empresas distribuidoras.

Os registros chamados de verdadeiros positivos ('a' na matriz de confusão - registros que obtiveram 3 ou mais votos na avaliação do comitê, e que receberam como resposta da inspeção o status de irregular), e os chamados de verdadeiros negativos ('d' na matriz de confusão - registros que receberam menos de 3 votos do comitê e possuem status de inspeção como normal), farão parte do conjunto de dados utilizado na etapa de treinamento do Módulo de Classificação. Os registros chamados de falsos positivos (que receberam 3 ou mais votos do comitê porém possuem resultado de inspeção como normal) e falsos negativos (que receberam menos de 3 votos do comitê mas foram indicados como irregular pela inspeção) serão descartados na próxima etapa, devido ao fato de que esses registros trazem ruídos significativos para a base de dados. Esta etapa somente é executada no treinamento do modelo, seguida da etapa de classificação.

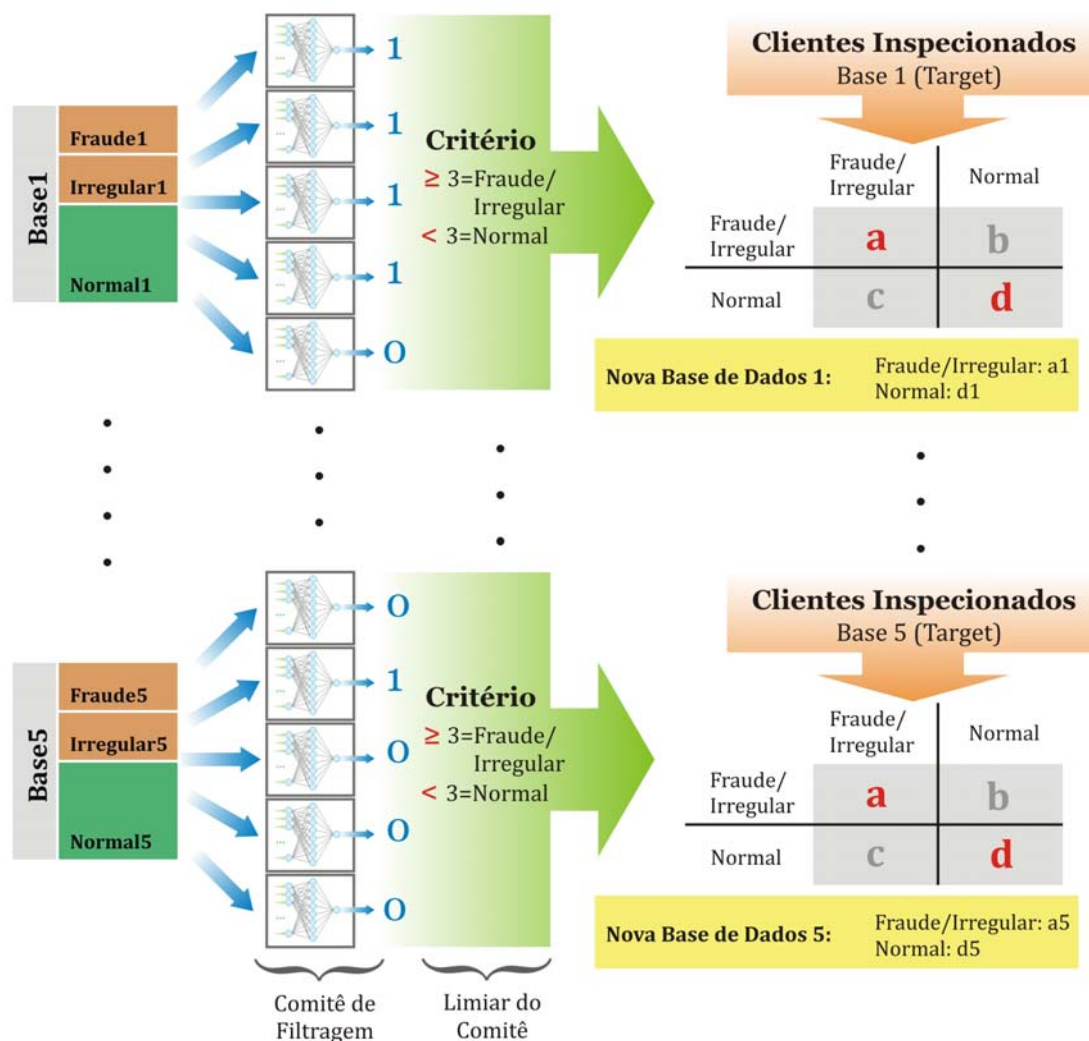


Figura 3 – Comitê de Filtragem vs Matriz de Confusão.

As 5 novas bases filtradas, extraídas das 5 bases antigas, são formadas pelos registros de valores Verdadeiros Positivos 'a' (V+) e os registros de Verdadeiros Negativos 'd' (V-), as quais são utilizadas como entrada para o treinamento do comitê presente na segunda etapa, a etapa de 'Classificação'.

Deste modo, conforme já mencionado, para o uso do modelo proposto pela empresa, os registros futuros são apenas submetidos à avaliação do Módulo de Classificação, não passando pelo comitê de filtragem (Figura 2).

3.3 Módulo 3: Classificação

O procedimento executado no Módulo de Classificação é rigorosamente o mesmo do procedimento utilizado no Módulo de Filtragem, sendo composto de um comitê de 5 Redes Neurais. O que difere a etapa de filtragem da de classificação é a base de dados utilizada para o treinamento do comitê de classificação. No caso do Módulo de Classificação, apenas os clientes selecionados pelo Módulo de Filtragem (aqueles clientes indicados como Verdadeiros Positivos e Verdadeiros Negativos na etapa anterior) são utilizados para o treinamento. Neste terceiro módulo, portanto, se procura uma melhor caracterização entre os clientes verdadeiramente Fraudadores/Irregulares e clientes verdadeiramente Normais.

Depois de concluído o processo de treinamento, o módulo de Classificação está pronto para ser utilizado com os novos padrões de entrada. Nesta nova fase (*recall*), o módulo de Filtragem não é mais necessário (Figura 2), e apenas será utilizado novamente quando houver necessidade de um retreinamento do sistema.

3.3.1 Construção de base de dados para a Classificação

Conforme descrito na seção anterior, as novas bases de dados filtradas são geradas com a ajuda de um Comitê de Filtragem com 5 redes neurais e uma matriz de confusão (Figura 3). Obtém-se assim 5 bases formadas pelos verdadeiros clientes

Fraudadores/Irregulares (Verdadeiros Positivos 'a') e Normais (Verdadeiros Negativos 'd'). Cada uma dessas 5 novas bases é embaralhada, homogeneizada e também subdividida em 2 partes: Treinamento (75%), Validação (25%).

Cada rede neural utilizada no módulo de 'Classificação', possui a mesma estrutura utilizada no Módulo de Filtragem, com n atributos de entrada, 1 camada oculta de neurônios, e 1 neurônio na camada de saída. O neurônio de saída, denominado Indicador de Irregularidade, apresenta apenas 2 classes: clientes suspeitos de Irregularidade/Fraude e clientes Normais (sem Irregularidades).

3.4 Modelo de Redes Neurais

As redes neurais artificiais que compõem os dois comitês são do tipo MLP (multi-layer perceptron) [5]. A escolha da topologia de uma rede neural depende de uma série de fatores, mas o número de atributos de entrada e de saída da rede neural, bem como a quantidade de registros na base de dados utilizada no treinamento, fornece uma boa diretriz para esta escolha.

As redes neurais (Figura 4) que compõem os comitês foram desenvolvidas no toolbox de redes neurais do programa Matlab[®] e possuem:

- 21 entradas: contendo aquelas descritas na seção 3.1 (origem, medidor, monobitri, etc), informação do consumo do mês anterior ao mês que houve a inspeção, e 4 médias móveis: consumo médio trimestral, semestral, anual e anual do ano anterior ao de referência de cada cliente, a partir do mês que houve inspeção;
- 1 uma camada escondida: com função de ativação do tipo *logsigmoidal*, e número específico de neurônios (definido através do conjunto de validação);
- 1 camada de saída: com 1 neurônio.

De acordo com este modelo, a variável de saída representa 2 classes: clientes suspeitos de irregularidade (técnica ou não técnica) e a de clientes sem irregularidades. O erro do conjunto de validação é monitorado para garantir a capacidade de generalização da rede. Este método, chamado de *early stopping*, determina um ponto de parada no treinamento, tentando encontrar um ponto ótimo de generalização. Quando o erro do conjunto de validação começa a aumentar o processo de treinamento é interrompido. O treinamento das redes neurais foi realizado com o algoritmo Back Propagation com Levenberg-Marquardt [5]. O treinamento das redes neurais com este algoritmo é da ordem de 10 a 100 vezes mais rápido que o Back Propagation original, mas é restrito quanto ao tamanho da rede neural (que deve conter uma quantidade moderada de pesos) e ao tamanho da base de dados, que não pode ser muito extensa.

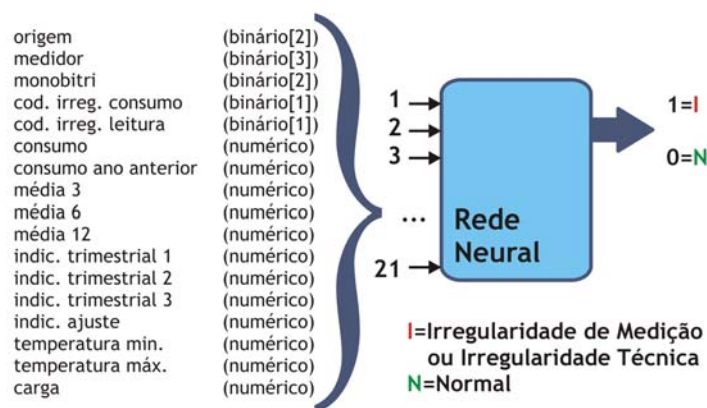


Figura 4. Topologia de Rede Neural MLP com uma saída

4 Resultados Experimentais

4.1 Base de Dados de Filtragem

Após o processamento dos dados selecionados (vide Subseção 3.1) obtém-se três bases de dados. A Tabela 3 identifica as três bases (clientes com irregularidade não técnica, clientes com irregularidade técnica e clientes normais), mostrando o número de clientes por base.

Tabela 3. Composição da Base de Dados para Filtragem

Cientes	Treinamento/Validação (registros)
Irregularidade não técnica	4159
Irregularidade técnica	3754
Normais	14405

Os dados relativos ao Treinamento/Validação são do período entre março de 2005 e junho de 2006, com exceção dos meses de fevereiro e março de 2006; já os dados da base de testes são de clientes investigados nos meses de fevereiro, março (avaliação de clientes durante o verão), julho e agosto de 2006 (avaliação em meses de inverno). Utilizou-se uma base de dados equilibrada, contendo 3754 registros de clientes com irregularidade técnica, 3754 registros, escolhidos aleatoriamente, de clientes com irregularidade não técnica, e 7508 amostras (também escolhidas aleatoriamente) de clientes normais, para que as duas classes de saída tenham o mesmo número de registros. A base de treinamento foi composta com 75% das amostras para treinamento e o restante da base para a validação.

Foram criadas cinco bases de dados diferentes, cada uma dando origem à de treinamento de cada uma das cinco redes que compõem o comitê. Para cada base de dados criada, realizaram-se 10 treinamentos e selecionou-se, para compor o comitê, a rede que obteve o melhor desempenho na fase de validação. Foram também realizados vários experimentos a fim de determinar o número de neurônios na camada escondida das redes. Segundo os resultados obtidos nos experimentos, a melhor topologia para as redes deste modelo foi a que contém oito neurônios na camada escondida.

Como o objetivo deste trabalho é aumentar o VPP de clientes com irregularidade de medição, foram feitos dois experimentos: um considerando o VPP como métrica de erro na validação do treinamento das redes neurais dos comitês; e outro considerando o erro de classificação geral dos dados. Observou-se que a métrica de erro de classificação obteve melhores resultados, pois ao minimizar o erro de classificação de ambas as classes, indiretamente ele também maximiza o VPP na identificação de clientes com irregularidade de medição. Por este motivo, nos resultados experimentais seguintes, utilizou-se a métrica de erro de classificação.

Além disso, foram avaliados diversos testes com limiares de filtragem e limiares de comitê de filtragem de formar a maximizar o VPP.

4.2 Base de Dados de Classificação

Após a filtragem dos dados pelo comitê da etapa anterior, obtiveram-se três novas bases de dados. A Tabela 4 identifica as três bases, mostrando o número de clientes por base.

Tabela 4. Composição da Base de Dados para Classificação

Cientes	Treinamento/Validação (registros)
irregularidade não técnica	2966
irregularidade técnica	1955
normais	9065

O mesmo procedimento utilizado na etapa de filtragem para uniformizar o tamanho das bases foi utilizado na etapa de classificação. Assim, utilizou-se uma base de dados com os 1955 registros de clientes com irregularidade técnica, 1955 registros, escolhidos aleatoriamente, de clientes com irregularidade não técnica, e 3910 amostras (também escolhidas aleatoriamente) de clientes normais, para que as duas classes de saída tenham o mesmo número de registros. A base de treinamento foi composta com 75% das amostras para treinamento e o restante da base para a validação.

Da mesma forma que no caso anterior, foram criadas cinco bases de dados diferentes, cada uma para o treinamento de cada uma das cinco redes que compõem o novo comitê de classificação.

4.3 Resultados dos testes de Filtragem

Após o treinamento das redes neurais do comitê, foi realizado um teste com uma base composta por clientes investigados nos meses de fevereiro, março, julho e agosto de 2006. Esta base de teste possui 4666 registros de clientes inspecionados nos quatro meses acima, sendo 1097 registros da classe de clientes com irregularidade não técnica, 435 da classe de clientes com irregularidade técnica e 3134 da classe de clientes normais. A Tabela 5 ilustra a matriz de confusão de cada rede deste comitê no teste realizado. O código F indica os clientes com irregularidade técnica e não técnica e o código N os clientes normais.

Outra métrica utilizada para avaliar o desempenho do modelo proposto foi a sensibilidade. Esta métrica é definida como o número de clientes classificados pela rede (ou pelo comitê) como irregulares e o número total de irregularidades comprovadas. Segundo a Tabela 1, a sensibilidade é expressa por:

$$\text{Sensibilidade} = \frac{a}{(a + c)} \tag{4}$$

Tabela 5. Resultados obtidos individualmente pelas redes do comitê de filtragem

Rede	Matriz de Confusão				Métricas
1	Saída		Target		VPP _{RN} : 44,2% Sensibilidade: 51,0% Erro Classific.: 37,2% VPP Light: 32,8%
			F	N	
	Rede	F	782	988	
		N	750	2146	
2	Saída		Target		VPP _{RN} : 46,1% Sensibilidade: 62,7% Erro Classific.: 36,3% VPP Light: 32,8%
			F	N	
	Rede	F	960	1124	
		N	572	2010	
3	Saída		Target		VPP _{RN} : 39,6% Sensibilidade: 64,4% Erro Classific.: 43,9% VPP Light: 32,8%
			F	N	
	Rede	F	986	1502	
		N	546	1632	
4	Saída		Target		VPP _{RN} : 40,1% Sensibilidade: 70,6% Erro Classific.: 44,3% VPP Light: 32,8%
			F	N	
	Rede	F	1082	1618	
		N	450	1516	
5	Saída		Target		VPP _{RN} : 44,1% Sensibilidade: 56,1% Erro Classific.: 37,8% VPP Light: 32,8%
			F	N	
	Rede	F	859	1090	
		N	673	2044	

A Tabela 6 ilustra a votação do comitê de filtragem. A votação é contabilizada (por rede neural) para cada cliente de teste da seguinte forma: os clientes que receberam 3 ou mais votos são classificados como irregulares. Os que receberam 2 ou menos votos são classificados como normais. Verifica-se que o resultado do comitê trouxe uma grande vantagem se comparado com o pior resultado de VPP (39,6%) das redes individuais; e em relação ao melhor resultado de VPP (46,1%) das redes individuais, a desvantagem que o comitê sofre é pequena.

Tabela 6. Resultados obtidos com o comitê de filtragem

Comitê	Saída		Target		VPP _{RN} : 45,2% Sensibilidade: 62,7% Erro Classific.: 37,2% VPP Light: 32,8%
			F	N	
	F	F	960	1164	
		N	572	1970	

4.4 Resultados dos testes de Classificação

Após o treinamento das redes neurais do comitê de classificação, foi realizado um teste com a mesma base utilizada para os testes da etapa de filtragem. A Tabela 7 ilustra a matriz de confusão de cada rede deste comitê no teste realizado.

A Tabela 8 ilustra a votação do comitê de classificação. A votação neste caso foi mais exigente, isto é, os clientes que receberam 4 ou mais votos são classificados como irregulares. Os que receberam 3 ou menos votos são classificados como normais. No caso da classificação, ao se comparar o resultado individual de cada rede com o resultado do comitê, verifica-se que o VPP do comitê é superior ao melhor valor de VPP (44,6%) das redes individuais. Quando se compara o resultado do comitê de filtragem com o de classificação, verifica-se que o VPP aumenta (de 45,2% para 46,0%) e o número de clientes indicados como irregular também aumenta (de 960 para 1038).

Tabela 7. Resultados obtidos individualmente pelas redes do comitê de classificação

Rede	Matriz de Confusão			Métricas
1	Saída		Target	VPP _{RN} : 43,8% Sensibilidade: 74,4% Erro Classific.: 39,7% VPP Light: 32,8%
			F N	
	Rede	F	1140 1462	
		N	392 1672	
2	Saída		Target	VPP _{RN} : 44,6% Sensibilidade: 72,3% Erro Classific.: 38,6% VPP Light: 32,8%
			F N	
	Rede	F	1108 1377	
		N	424 1757	
3	Saída		Target	VPP _{RN} : 40,5% Sensibilidade: 76,9% Erro Classific.: 44,7% VPP Light: 32,8%
			F N	
	Rede	F	1178 1734	
		N	354 1400	
4	Saída		Target	VPP _{RN} : 44,5% Sensibilidade: 68,0% Erro Classific.: 38,4% VPP Light: 32,8%
			F N	
	Rede	F	1041 1299	
		N	491 1835	
5	Saída		Target	VPP _{RN} : 42,7% Sensibilidade: 74,0% Erro Classific.: 41,2% VPP Light: 32,8%
			F N	
	Rede	F	1134 1524	
		N	398 1610	

Tabela 8. Resultados obtidos com o comitê de classificação

Saída		Target		VPP _{RN} : 46,0% Sensibilidade: 67,8% Erro Classific.: 36,7% VPP _{LIGHT} : 32,8%
		F	N	
Comitê	F	1038	1220	
	N	494	1914	

5 Conclusões

O assunto tratado neste artigo é de grande importância estratégica para as empresas distribuidoras de energia elétrica em todo o Brasil, uma vez que as perdas comerciais de energia elétrica por irregularidades representam um enorme prejuízo. Este artigo apresentou o desenvolvimento de uma metodologia baseada em redes neurais. O modelo utilizado é baseado em uma metodologia formada por duas etapas, uma de filtragem e outra de classificação, cada uma composta por um comitê de 5 redes neurais, onde cada rede possui uma saída para classificar os clientes em duas categorias: cliente com irregularidade e classe de clientes normais. O principal objetivo da modelagem utilizando comitês foi identificar quantitativamente o cliente irregular na classe irregularidade, fornecendo uma ordenação entre os diversos clientes supostamente irregulares. Essa ordenação ajuda ao operador na determinação das prioridades de inspeção. Quanto mais votos o cliente tiver, mais forte será a indicação desse cliente como suspeito. Ressalta-se a relevância do trabalho na identificação dos atributos relativos às médias móveis, indicadores trimestrais, anual, tendência e ajuste, além das variáveis que mapeiam a sazonalidade do consumo: temperaturas mínimas e máximas e carga própria total da empresa. A utilização dessas variáveis dispensou a necessidade de se usar um número maior de modelos fundamentais para caracterizar comportamentos distintos dos clientes conforme a variação do consumo ao longo do ano.

Segundo os resultados dos testes utilizando-se o modelo proposto para os clientes do tipo residencial, observa-se que o modelo atinge um VPP (relação entre o número de casos em que se detecta a irregularidade de medição, dividido pelo número de casos indicados para inspeção) de 46%, valor superior aos 25% obtidos pela Light usando os métodos apresentados na Seção 2, e maior que os 32,8% observados no conjunto de dados utilizado para teste. Outro fator importante é que dos 2408 clientes indicados como normais, 1914 (79,5%) não possuem irregularidade, dessa forma, o número de inspeções a se realizar diminui significativamente (61% de redução).

Apesar da redução de histórico e de atributos nos dados originais da empresa, os valores obtidos com o VPP apresentados nesse trabalho estão próximos aos valores anteriores, porém a sensibilidade obtida melhorou substancialmente [3][9]. Dessa forma, pode-se concluir que os resultados apresentados demonstram que o modelo proposto é bastante promissor no problema de identificação de irregularidades em baixa tensão, o que estimula a aplicação dessa nova metodologia para todos os clientes da Light.

Como trabalho futuro pretende-se estender a análise aos clientes não residenciais e a outras ZEIs. Além disso, serão investigados modelos baseados em Sistemas Neuro-Fuzzy Hierárquicos [6][17] para classificação, com o objetivo de extrair regras que possam identificar clientes irregulares, aumentando a interpretabilidade das relações entre as variáveis de entradas relevantes e a identificação do cliente irregular.

Referências Bibliográficas

- [1] Bishop, C.M. (1995). *Neural Networks for Pattern Recognition*, Oxford University Press.
- [2] Cabral, J. E., Gontijo, E. M., Pinto, J. O. P., and Filho, J. R. (2004). Fraud detection in electrical energy consumers using rough sets. In *2004 IEEE International Conference on Systems, Man and Cybernetics*, volume 4, pages 3625–3629.
- [3] Chaves, G. de Suspeitos de Irregularidade em Instalações Elétricas de Baixa Tensão, Dissertação de Mestrado, DEE, PUC-Rio, 2008.
- [4] Dash, M. and Liu, H. (1997). Feature Selection for Classification, *Intelligent Data Analysis*, 1(3), 1997. Em: http://www.tnt.uni-hannover.de/~rost/muster_erk/article.html
- [5] Haykin S. (1999). *Neural Networks - A Comprehensive Foundation*. 2 ed. New Jersey: Prentice-Hall, 1999. ISBN 0-13-273350-1.
- [6] Gonçalves, L. Vellasco, M., Pacheco, M., Souza, F. (2006). Inverted Hierarchical Neuro-Fuzzy BSP System: A Novel Neuro-Fuzzy Model for Pattern Classification and Rule Extraction in Databases, *IEEE Transactions on Systems, Man & Cybernetics, Part C: Applications and Review*, Vol. 36, No. 2, pp. 236-248.
- [7] Junior, J. E. C. (2005) Detecção de Fraudes em Unidades Consumidoras de Energia Elétrica Utilizando Rough Sets, Diss. de Mestrado, UFMS – Fund.Univ. Fed. Mato Grosso do Sul.
- [8] Mardia, K.V; Kent, J.T; Bibby J.M. (1979) *Multivariate Analysis*. Academic Press Inc. London.
- [9] Muniz, C., Figueiredo, K., Vellasco, M., Chavez, G. and Pacheco, M. (2009) Irregularity Detection on Low Tension Electric Installations, *International Joint Conference on Neural Networks (IJCNN'2009)*, Atlanta, USA, 14-19 June.
- [10] Pollock, D. S. G. (1999). *A Handbook of Time-Series Analysis, Signal Processing and Dynamics*. Academic Press, New York, San Diego Edition.
- [11] Provost, F., Fawcett, T., Kohavi, R. (1998). The Case Against Accuracy Estimation for Comparing Induction Algorithms. In *Proceedings of the Fifteenth International Conference on Machine Learning*, pp. 445–453 Madison, WI. Morgan Kaufmann.
- [12] Rauber, T.; Drago, I., Varejão, F. e Queiroga, R. (2005) Extração e Seleção de Características na Identificação de Perdas Comerciais na Distribuição de Energia Elétrica, *XXV Cong. Soc. Bras. Comp.*
- [13] Rong, J., Tagaris, H., Lachsz, A., and Jeffrey, M. (2002). Wavelet based feature extraction and multiple classifiers for electricity fraud detection. In *2002 Trans. and Distribution Conf. and Exhibition 2002: Asia Pacific. IEEE/PES*, vol. 3, pp. 2251–2256.
- [14] Santos, R., Vellasco, M., Artola F. and Fontoura, S. (2003). Neural Net Ensembles for Lithology Recognition, *4th Int. Workshop on Multiple Classifier Systems*, LCNS 2709, Springer.
- [15] Santos, R., Artola, F., Fontoura, S., Vellasco, M. (2002) *Lithology Recognition by Neural Network Ensembles*, Lecture Notes in Artificial Intelligence – Advances in Artificial Intelligence (LNAI 2507), Proceedings of the 16th Brazilian Symposium on Artificial Intelligence (SBIA'02), pp. 302-312, Springer Verlag.
- [16] Sharkey, A.J.C (1999). 'Combining Artificial Neural Nets: Ensemble and Modular Multi-Net Systems' – Perspectives in Neural Computing, Springer Verlag.
- [17] Vellasco, M., Pacheco, M., Figueiredo, K., Souza, F. (2008) Hierarchical Neuro-Fuzzy Systems - Part I, "Encyclopedia of Artificial Intelligence", Editors: Juan R. Rabañal, Julián Dorado & Alejandro Pazos, Information Science Reference