



**XX Seminário Nacional de Distribuição de Energia Elétrica
SENDI 2012 - 22 a 26 de outubro
Rio de Janeiro - RJ - Brasil**

Altamiro Veríssimo da Silveira Jr.
Choice Technologies S/A
altamiro.junior@choice.com.br

OTIMIZAÇÃO DO PROCESSO DE RECUPERAÇÃO DE ENERGIA ELÉTRICA EM FATURAS IRREGULARES VIA REDES NEURAIAS

Palavras-chave

Cálculo de faturas irregulares
Métodos de apoio à decisão
Otimização de processos
Redes Neurais Artificiais

Resumo

Resumo: Neste trabalho foi proposto um algoritmo de otimização baseado em uma rede neural artificial (RNA), com objetivo de auxiliar no processo de definição do período irregular de consumo de energia elétrica mais apropriado para efeito de faturamento de perdas comerciais, em função do histórico de arrecadação da instalação autuada e da energia desviada no respectivo período irregular considerado, implicando desta forma no aumento da energia faturada da concessionária sem prejuízo da energia arrecadada. Testes iniciais realizados se mostram coerentes com o objetivo proposto, otimizando o resultado do processo de recuperação de energia desviada.

1. Introdução

1. INTRODUÇÃO

O combate às perdas comerciais tem-se tornado recentemente objeto de vários estudos e pesquisa [1,2,3], em função da quantidade significativa de energia desviada mediante procedimentos irregulares, prejudicando a arrecadação das concessionárias.

Dentre as estratégias adotadas na identificação de procedimentos irregulares de consumo, a inspeção pode ser considerada a mais simples e apresenta um baixo custo, sendo porém pouco eficiente, considerando um cenário de altas taxas de reincidência. Estratégias mais avançadas baseadas em algoritmos de inteligência computacional tem se apresentado como uma ferramenta eficaz no processo de identificação de perdas comerciais, sendo cada mais utilizados, em função de resultados obtidos. Em [4] foi realizada uma

comparação entre vários classificadores baseados em transformada de *Fourier*, *wavelets* e regressão polinomial, para identificação de padrões de fraude. Em [5,6,7] utilizou-se mapas auto-organizáveis (SOM) na identificação de padrões de fraude em consumidores de alta tensão. Em [8] foi utilizado um classificador neuro-fuzzy na identificação de padrões irregulares de consumidores de baixa tensão.

A segunda etapa do processo de combate às perdas consiste na recuperação da energia não-faturada de uma UC autuada por procedimento irregular, devendo-se estimar portanto o período irregular de consumo, para posterior faturamento. Esta tarefa requer uma avaliação mais minuciosa do histórico de consumo da unidade, estabelecendo de forma coerente o início do período irregular. Neste caso também, justifica-se a aplicação de técnicas de inteligência computacional no processo de otimização do cálculo de perdas, visando aumentar o faturamento sem prejuízo da arrecadação.

Em um estudo conduzido pela Choice Technologies em Novembro de 2009 para concessionária de energia de um estado do Nordeste, verificou-se que o setor responsável pela avaliação de faturamentos irregulares costumava considerar como referência para efeito de cálculo de consumo não-registrado o mês mais próximo do ponto de autuação, limitando a energia recuperada. Entre Jan/2009 e Out/2009, apenas na regional São Luís, estimou-se que esse procedimento fez a concessionária deixar de faturar cerca de 5GWh em função deste procedimento adotado.

Este trabalho de pesquisa emergiu dentro deste contexto e consiste em desenvolver uma ferramenta matemática utilizando Redes neurais artificiais, de forma a contribuir no processo de otimização do cálculo das faturas irregulares. O algoritmo desenvolvido efetua uma ponderação do nível de consumo do cliente *versus* a energia que seria calculada em cada mês onde uma irregularidade pode ter-se iniciado, indicando desta forma o mês de referência mais apropriado para o faturamento do período irregular.

2. Desenvolvimento

2. PROPÓSITO

Este trabalho tem como objetivos:

- Aumentar a energia faturada
- Aumentar a taxa de arrecadação por fraude

Nesse sentido, desenvolveu-se o algoritmo do sistema de apoio ao processo de cálculo de energia em faturas irregulares que pode ser subdividido em duas etapas:

I - Identificação de pontos do histórico de consumo segundo uma regra heurística, referenciados como possíveis indicadores de início do período irregular.

II - Utilização de um algoritmo de otimização para selecionar entre os pontos admissíveis, o mais apropriado para o faturamento, considerando a energia desviada no período irregular e o padrão regular de consumo.

Na primeira etapa adotou-se um método empírico, que indicava na maioria dos casos de fraude um

decréscimo no consumo em média superior a 15% do kWh faturado previamente. Desta forma, o algoritmo assinala os pontos com maior probabilidade de início da irregularidade no histórico de consumo, que serão considerados as alternativas do sistema no processo de otimização do faturamento das perdas comerciais decorrentes do procedimento irregular. Caso não seja possível aplicar este critério, o algoritmo não identifica nenhum ponto no gráfico. A Figura 1 apresenta o histórico de consumo de uma UC autuada e os respectivos pontos gerados pelo algoritmo na etapa inicial para efeito de definição posterior do período irregular ótimo.




Fig. 1. Histórico de consumo de uma UC irregular contendo os pontos gerados pelo algoritmo

Os pontos assinalados em verde representam as alternativas indicadas pelo algoritmo de início do período irregular. Depois de identificar os pontos compatíveis com o critério definido, o sistema deverá executar o próximo passo, selecionando o ponto que viabilize maior retorno financeiro, sem comprometer a arrecadação.

Desta forma, foi proposto neste trabalho, o emprego de uma Rede Neural Artificial (RNA) que estimará um ponto de referência para o cálculo da fatura devida da UC autuada, considerando o padrão regular de consumo, a energia faturada no período irregular e o período irregular máximo admissível, auxiliando no processo de indicação do ponto admissível mais pertinente.

3. MÉTODO

2.1. Metodologia do Cálculo

O processo de cálculo do consumo não-registrado segue as diretrizes estabelecidas no artigo 130 da resolução 414 de 2010 da ANEEL pertinentes a adoção de qualquer procedimento irregular da unidade consumidora que caracterize prejuízo para concessionária [9].

A resolução 414 da ANEEL prevê 3 critérios de cálculo para o faturamento relativo ao período considerado irregular: fator de correção, média dos 3 maiores consumos obtida no período máximo de 12 meses que antecede o início da irregularidade e por último o critério aplicado do fator de demanda. Este trabalho considera somente o segundo critério da média dos três maiores consumos para efeito de faturamento do período irregular.

2.2. Redes Neurais Artificiais

Uma rede neural artificial é um modelo matemático que simula uma rede de neurônios biológicos. A rede neural possui uma arquitetura de processamento paralelo e distribuído, de forma a receber uma série de sinais externos (variáveis de entrada) e produzir uma resposta desejada segundo um conjunto definido de regras. Os neurônios são dispostos em camadas, ativados por uma função não-linear e conectados entre si por pesos sinápticos, calculados ao longo do processo de treinamento [10].

O aprendizado da RNA consiste de um processo iterativo de atualização dos pesos, no qual é apresentada aleatoriamente uma série de padrões de entrada e saída, mapeados no conjunto de treinamento, expressando as relações entre as variáveis do processo e que deverão ser assimilados pela RNA, de forma a responder coerentemente a novos padrões, pertencentes ao *range* das variáveis de entrada considerado no treinamento. Após a comparação das saídas da RNA com as definidas no conjunto de treinamento para uma respectiva entrada, o desvio relativo é calculado e utilizado no processo de adaptação sináptica, no sentido de minimizar o erro relativo. Como parâmetro de avaliação de *performance* do processo de treinamento, considera-se o erro médio quadrático.

A Figura 2 ilustra o algoritmo do processo de treinamento de uma RNA por supervisão forte.

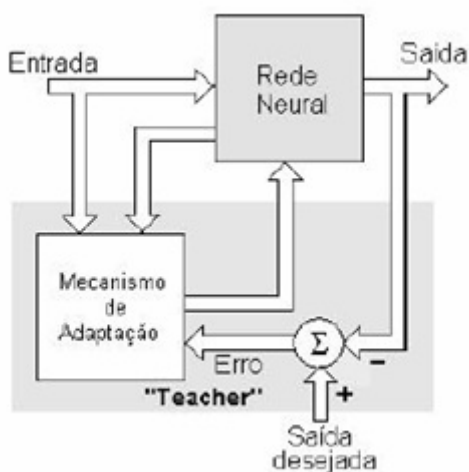


Fig 2. Estrutura do processo de aprendizado de uma RNA

2.3. Algoritmo de Otimização do Cálculo

Considerando-se a natureza não-linear do processo, utilizou-se uma rede neural *feedforward* com duas camadas escondidas, 5 variáveis de entrada e 3 de saída, função de ativação tangente hiperbólica em todas as

camadas, visando estimar um ponto no histórico da UC em função do padrão regular de consumo, da energia faturada no período irregular máximo admissível e do próprio período irregular máximo, para referenciar o processo de classificação, convergindo para o ponto mais coerente dentre aqueles gerados pelo algoritmo no processo de otimização, segundo a lógica definida no conjunto de treinamento. A Figura 3 apresenta com detalhes a configuração da Rede neural utilizada neste projeto, indicando as variáveis de entrada e saída da RNA, bem como o número de neurônios de cada camada e as respectivas funções de ativação que apresentaram o melhor resultado para o problema considerado.




Fig. 3. Configuração da Rede Neural Utilizada

As variáveis mais relevantes do processo foram consideradas como entradas da RNA na estimativa do ponto de referência mais apropriado. Na saída da RNA definiu-se 3 variáveis para determinação deste ponto no histórico da UC. Um limite superior e inferior para alocação da referência de cálculo, definindo desta forma um *range* apropriado, e um viés associado para uma ponderação adicional, situando o ponto de referência no intervalo estimado pela RNA em função da energia faturada no período irregular e da classe da unidade consumidora.

A Tabela 1 lista todas as variáveis de entrada da Rede neural utilizada, detalhando o respectivo significado de cada.

Tabela 1. Variáveis de entrada da RNA

x_{max}	Mês que define o início do período irregular máximo admissível
x_{min}	Mês que define o início do período irregular mínimo admissível

Kd_{ref_max}	<i>KWh</i> de referência para o cálculo da energia projetada no período irregular máximo
$Kd_{ref_min}(\%)$	<i>KWh</i> de referência para o cálculo da energia projetada no período irregular mínimo, expresso em porcentagem de Kd_{ref_max}
$E_fat(\%)$	Razão entre a energia faturada no período irregular máximo admissível e a energia projetada no mesmo período em função de Kd_{ref_max}

A Tabela 2 indica os limites definidos das variáveis correspondentes ao consumo de referência relativo ao período irregular máximo admissível (Kd_{ref_max}), bem como dos períodos irregulares máximos e mínimos (x_{max} e x_{min}), utilizados no conjunto de treinamento da RNA.

Tabela 2 – Limites das variáveis de entrada da RNA

Kd_{ref_max}	0.15 – 4.0 (MWh)
x_{max}	1 – 45 (nº meses)
x_{min}	1 – 27 (nº meses)

A Tabela 3 indica as variáveis de saída da Rede neural e o significado delas.

Tabela 3 – Variáveis de saída da RNA

$y_{sup}(\%)$	Limite superior <i>dorange</i> estimado pela RNA em porcentagem do período irregular máximo admissível
---------------	---

$y_{inf}(\%)$	Limite inferior <i>dorange</i> estimado pela RNA em porcentagem do período irregular máximo admissível
$q_{tz}(\%)$	Viés de quantização relativo <i>aorange</i> estimado para determinação do ponto de referência

O conjunto de treinamento contém no total 1460 pontos, mapeamento diferentes combinações possíveis entre x_{max} , x_{min} , E_{fat} e $Kd_{ref_{min}}$ para uma determinada classe de consumidor. Os *ranges* das variáveis de saída da RNA foram definidos a partir do histórico de arrecadação e de informações obtidas dos calculistas, ponderando o padrão regular de consumo da UC e a energia faturada relativa ao período irregular máximo admissível, estabelecendo um critério de faturamento conservador para consumidores de baixa renda e penalizando progressivamente consumidores de padrão mais elevado. O critério de otimização depende essencialmente da alocação dos marcos de fraude, do histórico de consumo, bem como da energia faturada no período irregular crítico, e consiste em definir um range mais pertinente no gráfico entre os períodos mínimo e máximo, a partir do histórico de arrecadação, não excedendo em média $4xKd_{ref_{max}}$ para consumidores de baixa renda e $6xKd_{ref_{max}}$ para consumidores de padrão superior.

No processo de aprendizado, utilizou-se o algoritmo de segunda ordem *Levenberg-Marquardt*, similar ao método de Newton, que apresentou o melhor desempenho no processo de convergência para o ponto ótimo [10]. A Figura 4 apresenta a convergência dos sinais dos erros médios quadráticos dos conjuntos de treinamento, teste e validação ao longo do processo de aprendizado por retro-propagação.

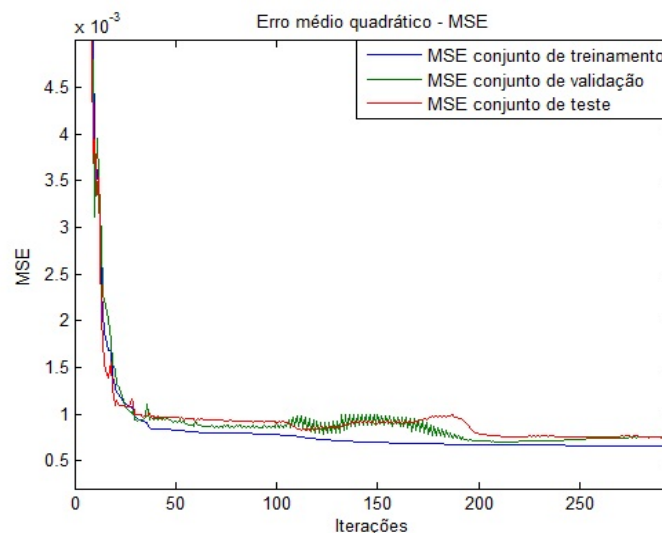


Fig. 4. Sinais dos erros médios quadráticos

4. DISCUSSÕES

Com objetivo de exemplificar a metodologia apresentada e avaliar o desempenho do algoritmo de otimização proposto, considerou-se inicialmente o caso de uma UC's do município de São Luís atuada por irregularidade. Todas as informações necessárias foram obtidas diretamente do sistema de banco de dados da concessionária local. Nas simulações do algoritmo de otimização foi utilizado o *software* Matlab versão 7.0.

A Figura 5 apresenta o histórico de consumo mensal em KWh da UC atuada e a simbologia das respectivas marcações no gráfico para aplicação do algoritmo proposto.

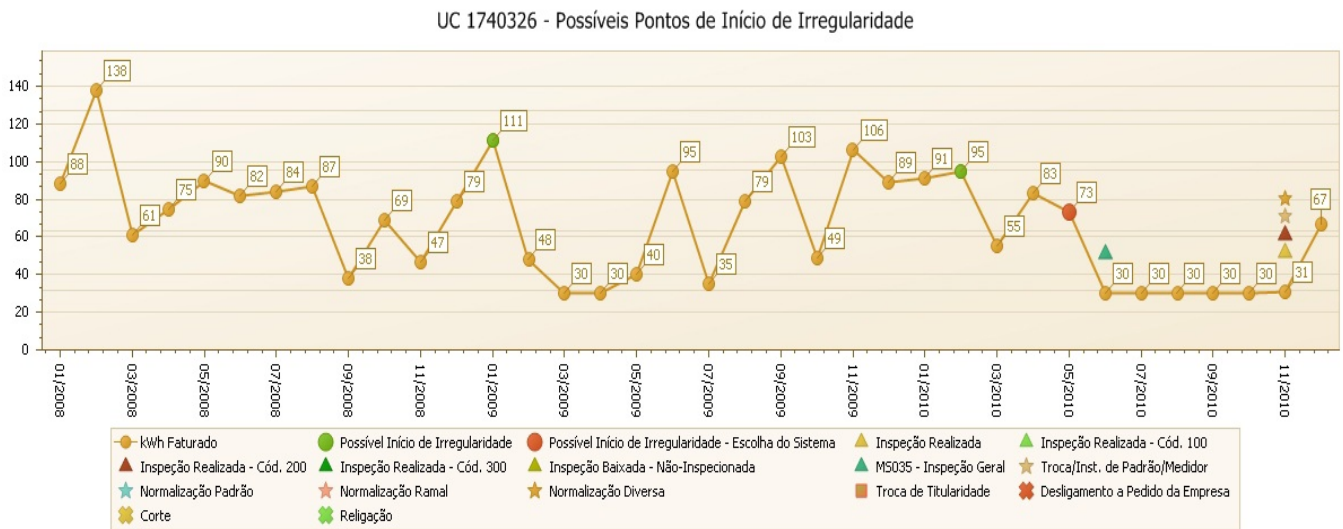


Fig 5. Histórico de consumo de uma UC atuada.

A Tabela 4 apresenta os valores calculados das variáveis de entrada da RNA, para estimativa do ponto que irá referenciar o processo de classificação em um dos pontos assinalados no gráfico, conforme a lógica descrita.

Tabela 4 – Variáveis de entrada da RNA

Kd_{ref_max} (Mwh)	x_{max}	x_{min}	$E_{fat}(\%)$	$Kd_{ref_min}(\%)$
0.113	22	6	0.547	0.896

A Tabela 5 indica o resultado obtido para as variáveis de saída da RNA correspondente à entrada acima.

Tabela 5 – Variáveis de saída da RNA

$y_{sup}(\%)$	$y_{inf}(\%)$	$q_{tz}(\%)$
0.377	0.2973	0.1616

O ponto de referência \hat{y}_{ref} , estimado pela RN é obtido da equação (1),

$$\hat{y}_{ref} = ((y_{sup} - y_{inf}) \cdot q_{tz} + y_{inf}) \cdot x_{max} \quad (1)$$

resultando em $\hat{y}_{ref} = 6.822$.

Na Figura 6, o triângulo azul representa o ponto de referência estimado pela RNA, utilizado para orientar o processo de classificação, consistindo na avaliação do erro de energia dos pontos mais próximos em relação ao ponto de referência. Desta forma, o ponto vermelho corresponde a alternativa mais coerente, implicando no menor erro em relação ao ponto estimado, determinando desta forma o período irregular, indicado no gráfico.




Fig. 6. Aplicação do algoritmo de otimização para faturamento de uma UC irregular

O gráfico da Figura 7 indica a energia calculada (413 KWh) em relação ao ponto selecionado de acordo com o critério definido.

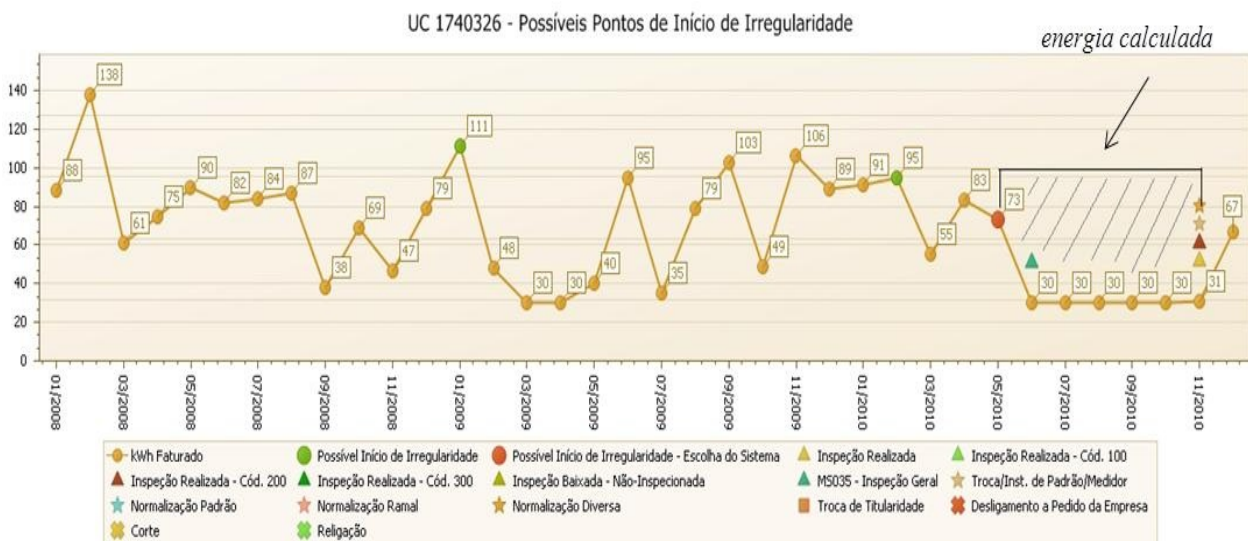


Fig. 7. Energia calculada em relação ao ponto selecionado

3. Conclusões

5. CONCLUSÕES

O *software* Matlab versão 7.0 foi empregado nas simulações do algoritmo de otimização. Posteriormente, o algoritmo de otimização proposto foi convertido em linguagem de banco Oracle PL/SQL para verificação de desempenho em todo o município de São Luís. O sistema encontra-se no momento em fase de testes e validação. Contudo, resultados iniciais se mostram coerentes com o objetivo proposto, no sentido de aumentar o faturamento sem prejuízo da arrecadação, tornando o processo de recuperação de energia subtraída otimizado e mais eficiente. A função gravidade financeira estima o total calculado para cada marco de fraude, e deverá ser revisada em função de novas políticas de cobrança adotadas pela concessionária.

4. Referências bibliográficas

7. REFERÊNCIAS

- [1] R. Jiang, H. Tagaris, A. Lachsz, “ Wavelet Based Feature Extraction and Multiple Classifiers for Electricity Fraud Detection”, *Transmission and Distribution Conference and Exhibition*, 3:2251-2256, 2002.
- [2] J. Nagi, A. M. Mohammad, K. S. Yap, S. K. Tiong, S. K. Ahmed, “ Non-Technical loss Analysis for Detection of Electricity Theft Using Support Vector Machine”, *2nd IEEE Conference on Power and Energy*, December 1-3, 2008, Malaysia.
- [3] M. D. Martino, F. Decia, J. Molinelli, A. Fernandez, “ Improving Electric Fraud Detection Using Class Imbalance Strategies” *ICPRAM, International Conference on Pattern Recognition Applications and Methods* , 2012.
- [4] T. D. Rauber I. Drago, F.M. Varejão, R.M. Queiroga, “Extração e Seleção de Características na Identificação de Perdas Comerciais na Distribuição de Energia Elétrica” *XXV Congresso da Sociedade Brasileira De Computação*, pp 1086-1089, Jul 2005.
- [5] F. A. C. Guimarães, “Detecção de fraudes em consumidores de energia elétrica da classe da Alta Tensão Horo Sazonal, utilizando Mapas Auto-Organizáveis Self-Organizing Maps (SOM), baseado em análise de memórias de massa ” Tese (Doutorado) – Curso de Engenharia Elétrica, Universidade de Mato Grosso do Sul, 2008.
- [6] I. Mondero, F. Biscarri, C. León, J. Biscarri, R. Millán, “ MIDAS: Detection of Non-Technical Losses in Electrical Consumption Using Neural Networks and Statistical Techniques”, *ICCSA, LNCS 3984*, pp. 725-734, 2006.

- [7] J. O. P. Pinto, E. M. Martins, A. M. A. Pinto, “ Fraud Detection in High Voltage Eletricity Consumers using Data Mining”, *IEEE-Transmission and Distribution Conference and Exposition*, 2008.
- [8] C. Muniz, M. Velasco, R. Tanscheit, K. Figueiredo, “ A Neuro-fuzzy System for Fraud Detection in Eletricity Distribution”, *IFSA-EUSFLAT-2009*.
- [9] ANEEL – Agência Nacional de Energia Elétrica: Resolução Normativa N⁰ 414, de 9 de Setembro de 2010.
- [10] S. Haykin, “Redes Neurais: Princípios e Prática”, 2a. Edição São Paulo: Makron Books, 1997.