

# **INTELIGÊNCIA ARTIFICIAL APLICADA À SUPERVISÃO DA QUALIDADE DE ENERGIA**

José Borges (Bolsista PIBIC/CNPQ), Aldebaro Klautau (Orientador)  
**Laboratório de Processamento de Sinais**  
**Departamento de Engenharia Elétrica e da Computação**  
**Universidade Federal do Pará**  
**CEP 66075-110, Belém – PA, tel: (91) 3201-7674**  
**{josevmb, aldebaro} @ufpa.br**

## **RESUMO**

O trabalho emprega técnicas de Inteligência Computacional procurando facilitar a análise e o diagnóstico de problemas em Qualidade de Energia, pois várias causas, desde naturais até manobras planejadas, podem comprometer essa qualidade e acarretar enormes prejuízos para concessionárias e contratantes. Desenvolveu-se um software em Java que captura o sinal recebido da placa de som, representa-o graficamente e realiza em tempo real o cálculo dos seguintes parâmetros de Qualidade de Energia: Transformada de Fourier Rápida (FFT, do inglês, Fast Fourier Transform), Distorção Harmônica Total (DHT) e Valor Eficaz. Também foi realizada uma avaliação entre os já consagrados algoritmos de Reconhecimento de Padrões: Árvore de decisão J.48, Naive Bayes e Redes Neurais. Os dados utilizados para essa avaliação foram gerados artificialmente no simulador Alternative Transient Program (ATP) e representam três sub-circuitos elétricos reais das Centrais Elétricas do Norte do Brasil (Eletronorte). Nestes dados, simularam-se situações de curto-circuito em linhas de transmissão com a localização e a duração da falta determinadas seguindo uma distribuição de probabilidade que pode ser uniforme ou gaussiana. Os resultados indicam que o algoritmo de árvore de decisão J.48 realizou a melhor classificação nas bases de dados utilizadas.

## **ABSTRACT**

The work uses Computational Intelligence in order to facilitate analysis and diagnosis of Power Quality problems, since many causes, from naturals to planned maneuvers, can compromise this quality and costs to concessionaires and contractors. There was developed a Java software that captures a signal from Sound Board, represents it graphically and realizes real-time calculation of the following Power Quality parameters: Fast Fourier Transform (FFT), Total Harmonic Distortion (DHT) and RMS value. There was also realized an evaluation through the already consecrated Pattern Discovery algorithms: Decision Tree J.48, Naive Bayes and Neural Nets. The data used for this evaluation were generated artificially on the simulator Alternative Transient Program (ATP) and represents three real electrical sub-circuits from Centrais Elétricas do Norte do Brasil (Eletronorte). In this data, there were simulated

transmission lines short circuits in which fault location and duration were determined in accordance with a probability distribution that may be uniform or gaussian. The results indicate that the Decision Tree J.48 algorithm realized the best classification on the used databases.

## INTRODUÇÃO

Entende-se por problema de Qualidade de Energia Elétrica (QE) qualquer alteração que possa ocorrer seja nas instalações de consumidores ou no sistema supridor da concessionária que resulte em má operação de equipamentos de consumidores. Os impactos econômicos da qualidade de energia são mais perceptíveis para consumidores do tipo industrial, uma vez que uma simples interrupção de curta duração pode causar danos gravíssimos como atrasar toda uma linha de produção elevando desta maneira os custos para a restauração do sistema. Existem setores, como as indústrias têxtil, siderúrgica e petroquímica, nos quais uma interrupção elétrica de até 1 minuto pode causar prejuízos da ordem de US\$500 mil (Franco, 2006).

Diante dessa situação, faz-se necessária uma análise e diagnóstico da qualidade da energia elétrica, no intuito de determinar as causas e as consequências dos distúrbios no sistema, além de apresentar medidas técnicas e economicamente viáveis para solucionar o problema. Os estudos em Inteligência Artificial surgem como meios de implementação de algumas dessas medidas. Um ramo específico da Inteligência Artificial é a Mineração de Dados (Data Mining, do inglês).

A Mineração de Dados é uma área de pesquisa de Inteligência Artificial que busca extrair conhecimento a partir de bases de dados. (Fernandes, 2003) Entre as técnicas de Mineração de Dados mais famosas, figuram as Redes Neurais, Árvores de Decisões, Estatísticas e Algoritmos Genéticos. Através destas técnicas, torna-se possível prever quando pode ocorrer um problema de QE, diagnosticá-lo e indicar sua localização no sistema elétrico com uma precisão bastante confiável, possibilitando às empresas concessionárias de energia a resolução do problema mais rapidamente e, acarretando assim, em prejuízos menores.

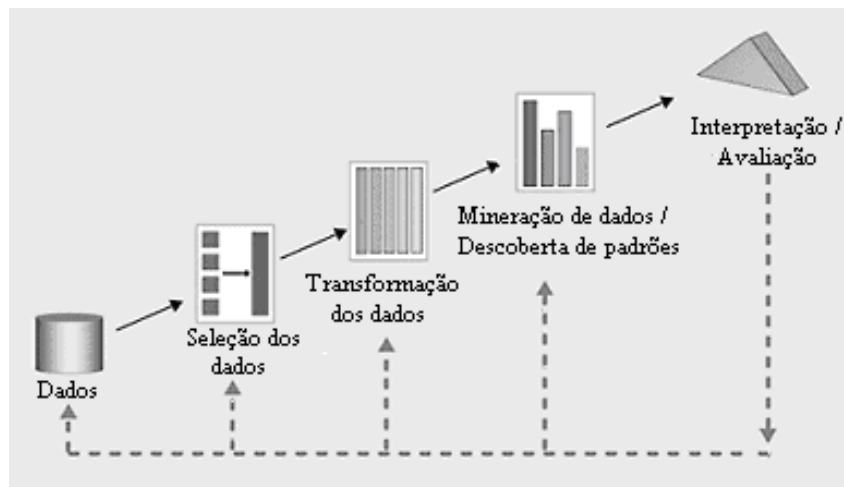


Figura 1 – Mineração de Dados.

## FERRAMENTA PARA SUPERVISÃO DA QUALIDADE DE ENERGIA

Existem poucos *softwares* dedicados à Supervisão da Qualidade de Energia no Brasil. Com base nessa necessidade, desenvolveu-se um *software* cujo objetivo é realizar a captura do sinal e o cálculo, em tempo real, dos parâmetros: “Fast Fourier transform” (FFT), Distorção harmônica total (DHT) e Valor eficaz. O *software* é escrito em Java e utiliza a biblioteca gráfica livre JFreeChart, para realizar a plotagem do sinal, este obtido através da placa de som do computador.

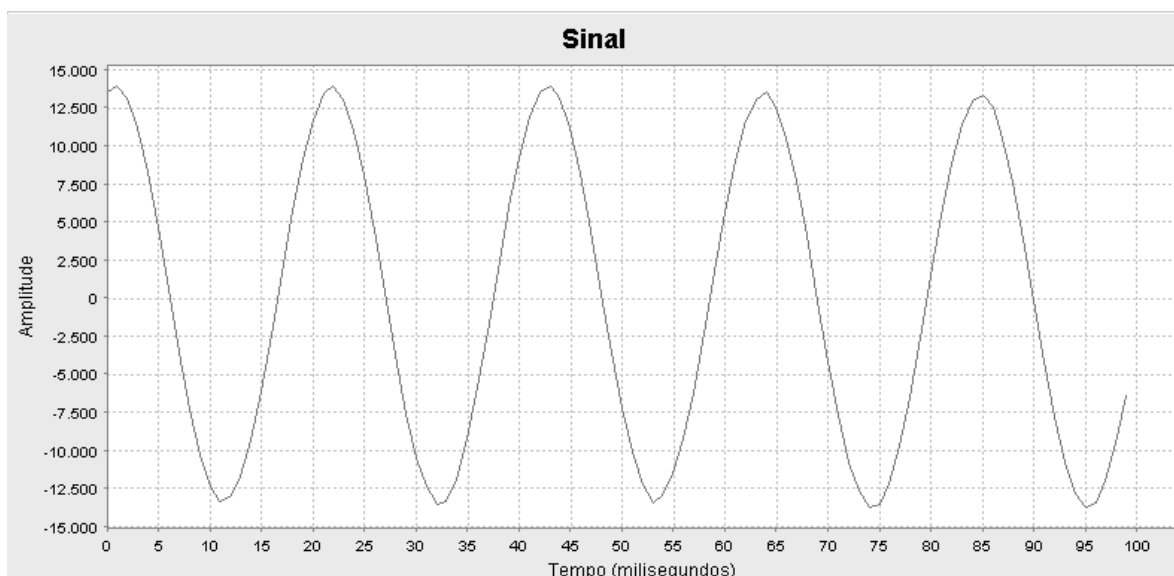


Figura 2. Interface gráfica de Captura do Sinal.

## AVALIAÇÃO DE ALGORITMOS

Foi realizada uma avaliação entre os já consagrados algoritmos de Reconhecimento de Padrões: Árvore de decisão J.48, Naive Bayes e Redes Neurais. O objetivo desta avaliação é encontrar qual destes algoritmos é aquele que melhor classifica o tipo de falta simulada.

### CONFIGURAÇÃO DAS BASES DE DADOS

As simulações foram feitas utilizando um pacote livre de algoritmos de Mineração de Dados chamado Weka. (WITTEN, 2005) Os classificadores utilizados foram os algoritmos da Árvore de decisão J.48, as Naive Bayes e o FastNeural, um algoritmo de redes neurais desenvolvido no Laboratório de Processamento de Sinais (LaPS) anteriormente ao projeto.

Os circuitos utilizados geraram formas de onda artificiais, a partir da simulação de sub-circuitos da rede elétrica da Eletronorte, gentilmente doados pela empresa. Os programas utilizados para simular os sub-circuitos foi o ATP e o ATPDraw, um pré-processador gráfico do ATP (no site <http://www.eeug.de/> há detalhes sobre o simulador e o seu pré-processador gráfico).

Os sub-circuitos correspondem aos trechos correspondentes ao Nordeste do Pará, à região de Marabá e ao trecho Tramoeste. O tempo de simulação em cada circuito é de 1 (um) segundo e

situações de faltas do tipo curto circuito em linhas de transmissão foram aleatoriamente inseridas nesse tempo seguindo uma distribuição de probabilidade, que pode ser uniforme e gaussiana.




Figura 3: Exemplo de uma interrupção ACT iniciando em 0,10s e finalizando em 0,20s, no circuito Tramoeste.

As faltas podem acontecer em qualquer momento e ter qualquer duração que respeite o tempo máximo. A rotulação é determinada pelo tipo de falta, podendo então o rótulo ser AT (fase A com Terra), BT, CT, AB (fase A com fase B), AC, BC, ABT, ACT, BCT, ABC, ACBT ou OK (quando não há falta). A especificação mais detalhada dos arquivos utilizados é encontrada na Tabela 1.

Tabela 1. Configuração geral das bases de dados

Número de Faltas	400
Janelamento	5
Frequência de amostragem	4000
Número de atributos do Weka	30
Número de instâncias das bases	320.000
Formato dos atributos	Real
Opções de Teste ou Tipo de “Experimenter” (Weka)	Supplied Test Set

## **RESULTADOS**

Nas tabelas a seguir, os algoritmos são avaliados em 3 quesitos: Instâncias classificadas incorretamente, tempo percorrido para construir o modelo e tempo percorrido em treinamento dos dados. Os dois últimos quesitos são utilizados para analisar a complexidade dos algoritmos e o primeiro (número de instâncias classificadas erroneamente) calcula a eficiência do algoritmo. Em negrito, destacam-se os melhores resultados.

Tabela 2. Resultados da base de dados "Marabá-Uniforme"

Base da dados utilizada: Marabá-Uniforme	Classificadores e configurações (parameters options)		
	<b>J.48</b> -C 0.99 -M 2 -L - S -A	<b>Naive Bayes</b>	<b>FastNeural</b> -L 0.3 -M 0.2 -N 500 -H 1 -V 0 -S 0 -E 20 -B -I -D
Instâncias classificadas incorretamente (%)	<b>11.78</b>	27.61	33.91
Tempo percorrido para construir o modelo (s)	3172.21	<b>60.48</b>	71925.96
Tempo percorrido em treinamento dos dados (s)	2.83	83058.66	<b>1.54</b>

Tabela 3. Resultados da base de dados "Tramoeste-Uniforme"

Base de dados utilizada: Tramoeste-Uniforme	Classificadores e configurações (parameters options)		
	<b>J.48</b> -C 0.99 -M 2 -L - S -A	<b>Naive Bayes</b>	<b>FastNeural</b> -L 0.6 -M 0.2 -N 500 -H 6 -V 0 -S 0 -E 20 -B -I -D
Instâncias classificadas incorretamente (%)	<b>9.05</b>	14.88	32.59
Tempo percorrido para construir o modelo (s)	2554.98	<b>61.00</b>	75330.39
Tempo percorrido em treinamento dos dados (s)	2.84	29549.75	<b>1.67</b>

Tabela 4. Resultados da base de dados "Nordeste-Uniforme"

Base de dados utilizada: Nordeste-Uniforme	Classificadores e configurações (parameters options)		
	<b>J.48</b> -C 0.99 -M 2 -L - S -A	<b>Naive Bayes</b>	<b>FastNeural</b> -L 0.3 -M 0.2 -N 500 -H 1 -V 0 -S 0 -E 20 -B -I -D
Instâncias classificadas incorretamente (%)	<b>20.30</b>	32.39	33.14
Tempo percorrido para construir o modelo (s)	10595.91	<b>92.33</b>	78247.71
Tempo percorrido em treinamento dos dados (s)	6.35	41930.49	<b>1.49</b>

Tabela 5. Resultados da base de dados “Marabá-Gaussiana”

Base de dados utilizada: Marabá-Gaussiana	Classificadores e configurações (parameters options)		
	<b>J.48</b> -C 0.99 -M 2 -L -S -A	<b>Naive Bayes</b>	<b>FastNeural</b> -L 0.3 -M 0.2 -N 500 -H 1 -V 0 -S 0 -E 20 -B -I -D
Instâncias classificadas incorretamente (%)	<b>7.00</b>	19.86	8.78
Tempo percorrido para construir o modelo (s)	6955.37	<b>328.29</b>	104511.38
Tempo percorrido em treinamento dos dados (s)	5.22	79513.19	<b>2.02</b>

Tabela 6. Resultados da base de dados “Tramoeste-Gaussiana”

Base de dados utilizada: Tramoeste-Gaussiana	Classificadores e configurações (parameters options)		
	<b>J.48</b> -C 0.01 -M 2 -L -S -A	<b>Naive Bayes</b>	<b>FastNeural</b> -L 0.3 -M 0.2 -N 500 -H 1 -V 0 -S 0 -E 20 -B -I -D
Instâncias classificadas incorretamente (%)	82.50	94.00	<b>8.89</b>
Tempo percorrido para construir o modelo (s)	5677.75	<b>253.67</b>	99732.38
Tempo percorrido em treinamento dos dados (s)	3.42	81748.56	<b>2.72</b>

Tabela 7. Resultados da base de dados “Nordeste-Gaussiana”

Base de dados utilizada: Nordeste-Gaussiana	Classificadores e configurações (parameters options)		
	<b>J.48</b> -C 0.01 -M 2 -L -S -A	<b>Naive Bayes</b>	<b>FastNeural</b> -L 0.3 -M 0.2 -N 500 -H 1 -V 0 -S 0 -E 20 -B -I -D
Instâncias classificadas incorretamente (%)	<b>5.29</b>	8.25	8.99
Tempo percorrido para construir o modelo (s)	9312.75	<b>74.13</b>	96337.12
Tempo percorrido em treinamento dos dados (s)	3.49	24761.15	<b>1.84</b>

## CONCLUSÃO

De acordo com os resultados obtidos, o classificador Naive Bayes obteve melhor performance em tempo de treinamento do modelo. Já em termos de erros de classificação a árvore J.48 obteve melhores resultados. A conclusão é baseada no teste padrão t-paired de significância estatística implementado pelo WEKA. A árvore de decisão J.48 requer menos

tempo de treino, no entanto, deve-se observar que o tempo de teste é freqüentemente o mais importante (dado que o treinamento pode ser feito off-line).

## **PALAVRAS CHAVES**

Qualidade de Energia (QE), Inteligência Computacional, Reconhecimento de Padrões.

## **AGRADECIMENTOS**

Agradeço a Deus, à toda minha família, em especial aos meus pais Estillac Borges e Bernadete Borges e meus irmãos Estillac Filho e João Luiz por sempre acreditarem em mim e incentivarem os meus estudos. Também agradeço à minha namorada Michelle Oliveira e a todos os meus amigos do Colégio Objetivo, do Condomínio Quinta de Évora, do Ideal e da UFPA. Agradeço a todos os alunos e professores do Laboratório de Processamento de Sinais, em especial aos meus companheiros do Projeto QESIA, pois sem eles esse trabalho não seria realizado. Agradeço ainda ao CNPQ, à UFPA, à Eletronorte e à PROPESP pela oportunidade de realizar essa pesquisa.

José Vieira Maciel Borges

## **REFERÊNCIAS**

- [1] FRANCO, Edgar; ENGECOMP TECNOLOGIA EM AUTOMAÇÃO E CONTROLE LTDA. **Qualidade de Energia - Causas, Efeitos e Soluções**. Artigo eletrônico, encontrado em: [http://www.engecomp.com.br/pow\\_qual.htm](http://www.engecomp.com.br/pow_qual.htm) (Último acesso em 10/12/2006)
- [2] FERNANDES, Anita Maria da Rocha. **Inteligência Artificial – NOÇÕES GERAIS**. Visual Books. Florianópolis – SC, 2003.
- [3] WITTEN, I., FRANK, E. **Data Mining: Practical Machine Learning Tools and Techniques with Java Implementations**. Mogan Kaufmann, 2<sup>nd</sup> edition, 2005.