



## APLICAÇÃO DE APRENDIZADO DE MÁQUINA NA ANÁLISE DE ASSINATURA ELÉTRICA EM UM MOTOR DE INDUÇÃO TRIFÁSICO

Primeiro Autor Apresentador\*<sup>1</sup>, Segundo Autor<sup>2</sup>, Terceiro Autor<sup>3</sup>, Quarto Autor<sup>1</sup>, Quinto Autor<sup>2</sup>, Sexto Autor<sup>3</sup>, Sétimo Autor<sup>1</sup> e Oitavo Autor<sup>2</sup>

<sup>1</sup>FEELT – Universidade Federal de Uberlândia

<sup>2</sup>FEMEC – Universidade Federal de Uberlândia

FACIV – Universidade Federal de Uberlândia

**Resumo** - A Análise de Assinatura Elétrica (AAE), é uma técnica de monitoramento capaz de diagnosticar avarias a partir dos sinais de tensão e de corrente, no circuito de alimentação de máquinas elétricas. Este artigo tem como intuito apresentar os resultados obtidos a partir de experimentos com uma rede neural artificial do tipo *Multilayer Perceptron* (MLP) e uma máquina de vetor de suporte (MVS) com as funções de *kernel* Polinomial, Sigmoidal e Gaussiana, que terão como finalidade a detecção de sete categorias diferentes de falhas em um motor de indução trifásico a partir dos seus valores de tensão e de corrente de linha. Ao término destes experimentos, as taxas de acerto obtidas serão avaliadas para que seja escolhida a melhor máquina de classificação.

**Palavras-Chave** - Análise de Assinatura Elétrica, Máquina de Vetor de Suporte, motor de indução trifásico, *Multilayer Perceptron*.

### ON APPLYING LEARNING MACHINES IN ELECTRICAL SIGNATURE ANALYSIS FOR A THREE-PHASE INDUCTION MOTOR

**Abstract** - Electrical Signature Analysis (ESA) is a technique for diagnosing faults from voltage and current signals in the power circuit of electrical machines. This paper has the aim to present the results obtained from experiments with a *Multilayer Perceptron* (MLP) artificial neural network and a *Support Vector Machine* (SVM) with polynomial, sigmoidal and gaussian kernel functions. Both machine learning techniques will be used for detecting seven different types of faults in a three-phase induction motor from their line voltage and current values. At the end of these experiments, the performance obtained will be evaluated to choose the best classification machine.

**Keywords** – Electrical Signature Analysis, *Multilayer Perceptron*, *Support Vector Machine*, *Three-Phase Induction Motor*.

\*primeiroautor@ufu.br

### I. INTRODUÇÃO

A Análise de Assinatura Elétrica compreende o conjunto de técnicas para análise da condição e prognóstico de falhas em equipamentos elétricos e dispositivos eletromecânicos, através do monitoramento de seus sinais elétricos [1]. Adicionalmente, estabelece que tal método utiliza, além do espectro de frequência em corrente, também o espectro de tensão em que, juntos, permitem avaliar a qualidade da energia fornecida à carga [2].

Sob estes aspectos, esta técnica foi implementada utilizando as técnicas conhecidas por Máquinas de Vetor de Suporte e Redes Neurais Artificiais, possibilitando realização do comparativo de desempenho destas duas técnicas.

A escolha destas duas técnicas se deu pelo fato da sua grande variedade de aplicações, em que autores já realizaram uma revisão a nível introdutório sobre os fundamentos da AAE, técnicas de detecção de faltas e apresentam, ainda, as assinaturas típicas de corrente que tipificam irregularidades no entreferro, no rotor, no estator, nas conexões dos enrolamentos, no rotor curvado diante de instabilidades térmicas, no rolamento e na caixa de engrenagens. Além disto, alguns autores destacam a importância do diagnóstico de falhas no processo de manutenção e mostram como as Máquinas de Vetor de Suporte podem ser utilizadas para esta finalidade, como uma ferramenta diagnóstica, mas também de predição [3-7].


A Máquina de Vetor de Suporte [8] é um algoritmo de aprendizado de máquina supervisionado que pode ser utilizado tanto em tarefas de classificação quanto em regressão. A sua ideia geral está baseada em: todo espaço de entrada original pode ser mapeado para um espaço de dimensão mais alta em que o conjunto de treinamento se torna separável.

Por sua vez, as Redes Neurais Artificiais [8] são modelos computacionais inspirados nos neurônios biológicos e na estrutura cerebral com capacidade de adquirir, armazenar e utilizar conhecimento. São compostas por várias unidades de processamento que são amplamente conectadas entre si por meio de caminhos sinápticos associados a determinado peso.

## II. MATERIAL E MÉTODOS

A representação esquemática do ambiente de treinamento das máquinas de classificação mencionadas anteriormente, para que sejam obtidos os seus respectivos desempenhos está ilustrado na Figura 1.

Figura 1: Ambiente de treinamento e teste dos classificadores.



A base de dados foi dividida em dois subconjuntos: de treinamento, composto por 80% das instâncias da base original, e teste com os 20% restantes. Procurou-se, ainda, garantir a presença, em cada um dos subconjuntos, as instâncias representativas de cada uma das falhas registradas nesta base.

Em seguida, os dados de treinamento (com a presença do rótulo de cada uma das instâncias presentes) são apresentados a rede neural artificial ou a máquina de vetor de suporte para que seus respectivos algoritmos de treinamento as utilizem com o intuito de obter a melhor representação possível do conhecimento adquirido por estes sistemas. Uma vez que os parâmetros ótimos do classificador foram conquistados, o subconjunto de teste é apresentado com a finalidade de medir o grau de generalização adquirido pelo classificador, culminando no levantamento da taxa de acerto.

### A. A base de dados

A base de dados utilizada neste trabalho é proveniente do trabalho de [10], em que foram simuladas as falhas em um motor de indução trifásico, rotor em gaiola, 1/3 hp. As faltas simuladas foram: subtensão, sobretensão, desbalanceamento de fase, rotor bloqueado, sobrecarga e falta de fase. Os dados de tensão e corrente foram adquiridos utilizando a plataforma LabVIEW. Todo o conjunto de dados está disponível em [10].

As instâncias desta base de dados são compostas das seguintes informações, na seguinte ordem:

rot	V1:v1	V2:v2	V3:v3	I1:i1	I2:i2	I3:i3
-----	-------	-------	-------	-------	-------	-------

onde:

- **rot**: valor inteiro correspondente ao tipo de falha;
- **V1**: tensão na fase 1 em volts;
- **V2**: tensão na fase 2 em volts;
- **V3**: tensão na fase 3 em volts;

- **I1**: corrente na fase 1 em ampères;
- **I2**: corrente na fase 2 em ampères;
- **I3**: corrente na fase 3 em ampères.

Os rótulos utilizados, condições operativas e a quantidade de padrões por falta da base de dados estão apresentadas na Tabela 1.

Tabela 1: Número de padrões por falta da base de dados [10].

Rótulo	Condição	Quant. de padrões
1	Sem falha	154
2	Falta de fase	85
3	Desbalanceamento de fase	450
4	Subtensão	49
5	Sobretensão	10
6	Rotor bloqueado	10
7	Sobrecarga	30
<b>Total</b>		<b>788</b>

Desta forma, foi realizada a elaboração dos subconjuntos de treinamento e de teste, com suas respectivas quantidades de padrões apresentadas pelas Tabelas 2 e 3, respectivamente.

Tabela 2: Número de padrões do subconjunto de treinamento.

Rótulo	Condição	Quant. de padrões
1	Sem falha	124
2	Falta de fase	68
3	Desbalanceamento de fase	360
4	Subtensão	40
5	Sobretensão	8
6	Rotor bloqueado	8
7	Sobrecarga	24
<b>Total</b>		<b>632</b>


Tabela 3: Número de padrões do subconjunto de teste.

Rótulo	Condição	Quant. de padrões
1	Sem falha	30
2	Falta de fase	17
3	Desbalanceamento de fase	90
4	Subtensão	9
5	Sobretensão	2
6	Rotor bloqueado	2
7	Sobrecarga	6
<b>Total</b>		<b>156</b>

### B. A rede neural artificial

Uma rede *Multilayer Perceptron*, conforme apresentada pela Figura 2, é utilizada para dados que possuem mais de duas classes, além de possuir mais de um neurônio na sua camada de saída. A MLP utiliza-se de um processo de treinamento supervisionado o ajuste de seus pesos para que seja obtida uma resposta desejada a partir da amostra de dados submetida a esta rede. A técnica de aprendizado que é aplicada no processo de treinamento é conhecida como *error backpropagation* [8].

Figura 2: Topologia de uma rede neural *multilayer perceptron*.



Para realizar a montagem da topologia da rede neural e obter o seu melhor *setup* foi utilizada a seguinte metodologia: (1) Como as instâncias da base são constituídas de 3 valores de tensão de linha, seguidos de 3 valores de corrente de linha, a camada de entrada é constituída de 6 neurônios; (2) A quantidade de neurônios da camada escondida seguiu as recomendações de [11]. Desta forma, as taxas de acerto obtidas estão relacionadas a 6 neurônios (TA-1) e 7 neurônios (TA-2); (3) A função de ativação utilizada foi a sigmoideal devido ao seu balanço entre um comportamento linear e não linear; (4) Os pesos sinápticos da rede neural foram inicializados com valores aleatórios dentro do intervalo  $[-0,5; +0,5]$ . Os valores foram gerados nesse intervalo pois um peso muito grande poderia levar os neurônios a saturação, fazendo assim com que a rede não venha a convergir; (5) O algoritmo de aprendizagem foi o *error backpropagation* [8], sem uso de momento e atualização instantânea dos pesos sinápticos; (6) Foi investigado o desempenho do sistema com passos de aprendizagem ( $\eta$ ) dentro do intervalo  $[+0,1; +1,0]$  com intervalos de 0,1; (7) O treinamento da ANN foi interrompido quando uma das condições foi satisfeita: o número limite de épocas foi alcançado, o número de erros de treinamento foi nulo, o valor de erro médio quadrático atingiu um limiar ( $\epsilon$ ) pré-estabelecido.

### C. A máquina de vetor de suporte


Da mesma forma que para a rede neural, executou-se experimentos utilizando um classificador SVM com a mesma base de dados obtida do trabalho de referência deste artigo. Foi utilizada a função *tune* do R para encontrar o parâmetro de custo da função Lagrange que daria o menor erro possível na função, esse parâmetro C é o limite da variável  $\alpha_i$  onde a mesma obedece a condição que os possíveis valores de  $\alpha_i$  estão entre 0 e C, ou seja  $0 \leq \alpha_i \leq C$ . Além desse parâmetro, foi comparado o parâmetro  $\gamma$  de acordo com a sugestão de [10], onde ele compara o  $\gamma$  padrão da função do SVM ( $\gamma = 1$ ) e um  $\gamma$  com valor de 0,5. Os *kernels* utilizados foram o linear, polinomial, gaussiano e sigmoideal, como pode ser observado na Tabela 4.

Tabela 4: Tipos de *kernel* utilizados.

Tipo de Kernel	Função
Polinomial	$K(x_i, x_j) = \left( 1 + \sum_j (\vec{x}_i \cdot \vec{x}_j) \cdot \gamma \right)^d$
Gaussiano	$\exp\left(-\frac{\ \vec{x}_i - \vec{x}_j\ ^2}{2\sigma^2}\right)$
Sigmoideal	$\tanh(\delta(\vec{x}_i \cdot \vec{x}_j) + k)$

As máquinas de vetor de suporte não lineares foram implementadas pois com elas é possível levar os dados para um espaço de maior dimensão, para que o problema se torne linearmente separável. Um espaço de características  $\Phi$  leva o espaço de entradas  $X$  para um espaço de características  $\zeta$  onde os dados serão linearmente separáveis, como pode ser visto na Figura 3.

Figura 3: Ampliação da dimensão do espaço de características para separação das classes.



Com efeito, um problema complexo de classificação de padrões, lançado em um espaço de alta dimensão não linearmente, tem maior probabilidade de ser linearmente separável do que em um espaço de baixa dimensão, desde que o espaço não seja densamente povoado.

## III. RESULTADOS E DISCUSSÃO

O melhor *setup* obtido para a rede neural foi com 6 neurônios na camada escondida, limiar de 0,1 e passo de aprendizado 0,3, resultando em uma taxa de acerto igual a 99,36%. Ao comparar com a taxa de acerto obtida por [10], nota-se que este *setup* vencedor superou os 98,67% de acerto.

Por sua vez, a máquina de vetor de suporte obteve os resultados registrados na Tabela 5.

Tabela 5: Resultados para cada tipo de *kernel*.

Tipos de Kernel	Taxa de acerto
Linear Padrão	80,13%
Polinomial Padrão	100%
Polinomial ( $\gamma = 0,5$ )	100%
Gaussiano Padrão	99,36%
Gaussiano ( $\gamma = 0,5$ )	100%
Sigmoideal Padrão	60,90%
Sigmoideal ( $\gamma = 0,5$ )	60,26%

O melhor resultado obtido encontra-se no SVM com *kernel* polinomial e gaussiano com  $\gamma = 0,5$ , onde conseguiu-se com o algoritmo obter 100% de taxa de acerto.

Para o *kernel* linear já se esperava um baixo desempenho devido a sua baixa adaptabilidade a dados que não são linearmente separáveis (maioria dos casos). Para esta base de dados quando é plotado o gráfico com as amostras nota-se a existência de sobreposição, e outro fator que agrava a má classificação do *kernel* linear se dá ao fato de que existem 7 classes de faltas o que torna muito difícil a total separabilidade de amostras.

No geral foi possível observar que os dois algoritmos em certos casos se obtiveram excelentes resultados. Utilizando como base os resultados de [10], o mesmo obteve para a rede neural com oito neurônios na camada escondida uma taxa de acerto de 98,67% e para SVM seu melhor resultado foi com *kernel* polinomial e gaussiano onde o mesmo conseguiu uma taxa de acerto de 100%. Os resultados deste trabalho aqui escrito, como já mostrados anteriormente, foram de 99,36% de acerto para a melhor configuração da rede neural e 100% de acerto para o teste de SVM polinomial e gaussiano. Assim é possível observar que este trabalho se equipara aos resultados de base.

#### IV. CONCLUSÕES

Este artigo teve como objetivo comparar o desempenho de duas técnicas de classificação (Redes Neurais Artificiais e Máquinas de Vetor de Suporte), em que ambas foram utilizadas para a classificação de falhas em um motor de indução trifásico, a partir de seus dados de tensão e de corrente.

Para se chegar ao melhor *setup* nas redes neurais artificiais, foi necessária a realização de uma estratégia conhecida como *tuning*, em que são elaborados diversos setups em que cada um deles é composto de uma definição dos valores dos parâmetros livres, com o intuito de obter a melhor taxa de acerto e, conseqüentemente, o menor erro médio quadrático. Adotando este procedimento, conseguiu-se obter uma taxa de acerto de 99,36%, superando os 98,67% obtidos em [10].

Por sua vez, o *tuning* também foi utilizada para encontrar o melhor conjunto de parâmetros para a máquina de vetor de suporte, fazendo com que fossem obtidos desempenhos similares aos encontrados em [10].

Como sugestão para trabalhos futuros, sugere-se a montagem de uma bancada de ensaios para a simulação de falhas nos motores elétricos presentes no Laboratório de Máquinas do IFMG – *Campus* Formiga. Desta forma, seria possível realizar a aquisição dos sinais de tensão e de corrente destas máquinas rotativas, para servir de instrumento de pesquisa e de aulas para os cursos de Engenharia Elétrica e técnico em Eletrotécnica.

Além da construção desta bancada de ensaios, sugere-se a construção de um *hardware* para que sejam embarcadas estas duas técnicas de classificação para que, em conjunto com a

bancada de ensaios, sejam realizados os procedimentos de manobra e proteção de motores elétricos.

#### REFERÊNCIAS

- [1] J. G. B. da Silva (2015). *Modelagem e tratamento dos sinais da assinatura elétrica de máquinas para melhoria do diagnóstico de falhas*. Acedido em 08 de Fevereiro de 2018, em: [https://repositorio.unifei.edu.br/xmlui/bitstream/handle/123456789/431/tese\\_silva\\_2015.pdf?sequence=1&isAllowed=y](https://repositorio.unifei.edu.br/xmlui/bitstream/handle/123456789/431/tese_silva_2015.pdf?sequence=1&isAllowed=y).
- [2] M. Maran (2011). *Manutenção baseada em condição aplicada a um sistema de ar condicionado como requisito para sustentabilidade de edifícios e escritórios*. Acedido em 08 de Fevereiro de 2018, em: [http://teses.usp.br/teses/disponiveis/3/3146/tde-12122011-142917/publico/Dissertacao\\_Marcos\\_Maran.pdf](http://teses.usp.br/teses/disponiveis/3/3146/tde-12122011-142917/publico/Dissertacao_Marcos_Maran.pdf).
- [3] D. Milkovic (2015). *Brief review of motor current signature analysis*. Acedido em 11 de Fevereiro de 2018, em: <https://hrcak.srce.hr/file/218882>.
- [4] S. B. Salem, K. Bacha, A. Chaari (2012). *Support vector machine-based decision for induction motor fault diagnosis using air-gap torque frequency response*. Acedido em 08 de Fevereiro de 2018, em: <http://research.ijcaonline.org/volume38/number5/pxc3876812.pdf>.
- [5] K. Deák, et. al. (2014). *Failure diagnosis with SVM in machine learning maintenance engineering*. Acedido em 08 de Fevereiro de 2018, em: <https://dea.lib.unideb.hu/dea/bitstream/handle/2437/194524/194524.pdf?sequence=2&isAllowed=y>.
- [6] S. Bhattacharyya, et. al. "Induction motor fault diagnosis by motor current signature analysis and neural network techniques". *Journal of Advanced Computing and Communication Technologies*, vol. 3, no. 1, pp. 12-18. 2015.
- [7] A. J. S. Reis (2010). *Reconhecimento de padrões de falhas em motores trifásicos utilizando redes neurais*. Acedido em 14 de Fevereiro de 2018, em: [https://repositorio.ufrn.br/jspui/bitstream/123456789/15341/1/AdersonJSR\\_DISSERT.pdf](https://repositorio.ufrn.br/jspui/bitstream/123456789/15341/1/AdersonJSR_DISSERT.pdf).
- [8] S. Haykin. *Redes neurais: teoria e prática*. Bookman, 2ª Edição, São Paulo, 2007.
- [9] R. Hammo (2014). *Faults identification in three-phase induction motors using support vector machines*. Acedido em 14 de Fevereiro de 2018, em: [https://scholarworks.bgsu.edu/cgi/viewcontent.cgi?article=1000&context=ms\\_tech\\_mngmt](https://scholarworks.bgsu.edu/cgi/viewcontent.cgi?article=1000&context=ms_tech_mngmt).
- [10] A. S. Ruela (2012). *Redes neurais feedforward e backpropagation*. Acedido em 20 de Março de 2018, em: [http://www.decom.ufop.br/imobilis/wp-content/uploads/2012/06/03\\_Feedforward-e-Backpropagation1.pdf](http://www.decom.ufop.br/imobilis/wp-content/uploads/2012/06/03_Feedforward-e-Backpropagation1.pdf).