

INFORMAÇÕES GERAIS DO TRABALHO

Título do Trabalho: Comparativo de desempenho de máquinas de vetor de suporte e de redes neurais artificiais em análise de assinatura elétrica

Autores: Jean Fonseca da Silva, Matheus Henrique Vieira Silva, Thales Henrique Damasceno Lima, José Antonio Moreira de Rezende

Palavras-chave: Análise de Assinatura Elétrica, motor de indução trifásico, rede neural artificial.

Campus: Formiga

Área do Conhecimento (CNPq): Engenharia Elétrica

RESUMO

A Análise de Assinatura Elétrica (do inglês ESA – *Electrical Signature Analysis*), é uma metodologia de monitoramento capaz de diagnosticar avarias, a partir dos sinais de tensão e de corrente, no circuito de alimentação de máquinas elétricas como, por exemplo, em motores de indução trifásicos. Desta forma, estas leituras são obtidas através de sensores instalados no próprio painel de alimentação da máquina, de forma a garantir a realização dos ensaios em máquinas com acesso restrito. Com efeito, os sinais provenientes destes sensores são obtidos, filtrados e armazenados para a detecção de falhas através de análises das assinaturas de corrente elétrica e suas respectivas tendências de evolução no tempo. Este resumo tem como objetivo apresentar os resultados parciais associados ao projeto de pesquisa em execução no IFMG Campus Formiga, sob regência do Edital N° 28, de 21 de dezembro de 2017, que propõe o comparativo de desempenho de duas técnicas de aprendizado de máquina, que são as Máquinas de Vetor de Suporte (MVS) e as Redes Neurais Artificiais (RNA), na tarefa de detecção de falhas em motores de indução trifásicos pela metodologia ESA. Tais resultados parciais foram obtidos a partir dos experimentos realizados em rede neural do tipo Perceptron Multicamadas (do inglês MLP – *Multilayer Perceptron*), com seis neurônios na camada de entrada e sete neurônios na camada de saída. Foram realizados testes na RNA com seis neurônios e, posteriormente, com 7 neurônios na camada escondida, com uma tolerância máxima de 0,1, assim como testes objetivando uma tolerância máxima de 0,2. Os resultados observados entre os testes citados, foi possível notar uma diferença de desempenho máxima de 10% (dez por cento), quando o número de neurônios da camada escondida foi aumentado. Como ainda é um projeto em andamento, ainda não foi possível realizar a comparação de desempenho entre RNA e MVS. As máquinas de vetor de suporte serão implementadas no segundo semestre de 2018.

INTRODUÇÃO:

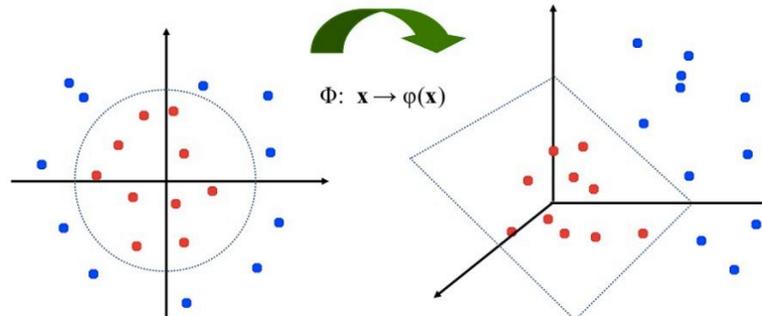
A Análise de Assinatura Elétrica, segundo Silva (2015): “compreende o conjunto de técnicas e metodologias para análise da condição e prognóstico de falhas em equipamentos elétricos e dispositivos eletromecânicos, através do monitoramento de seus respectivos sinais elétricos”. Por sua vez, Maran (2011), estabelece que tal método utiliza além do espectro de frequência em corrente, também o espectro de tensão em que, juntos, permitem avaliar a qualidade de energia.

Sob estes aspectos e no âmbito deste projeto de pesquisa, o método ESA será implementado utilizando as técnicas conhecidas por Máquinas de Vetor de Suporte (*Support Vector Machines - SVM*) e Redes Neurais Artificiais (*Artificial Neural Networks - ANN*), para que seja realizado o comparativo de desempenho destas duas técnicas. A escolha destas duas técnicas se dá pelo fato da sua grande aplicação, como pode ser visto em Milkovic (2015), Deák et. al. (2014), Salem, Bacha e Chaari (2012), Bhattacharyya et. al. (2015) e Reis (2010).

A Máquina de Vetor de Suporte, segundo Haykin (2007), 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, como pode ser visto na Figura 1.

Figura 1 - Transformação do espaço original em um espaço de mais alta ordem.



Seja a amostra de treinamento $\{(\mathbf{x}_i, d_i)\}_{i=1}^N$, onde \mathbf{x}_i é o padrão de entrada do i -ésimo exemplo e d_i a sua correspondente resposta desejada (ou rótulo, ou classe). Assumindo que as classes são linearmente separáveis, a equação da superfície de decisão do espaço de dimensão mais alta é dado por:

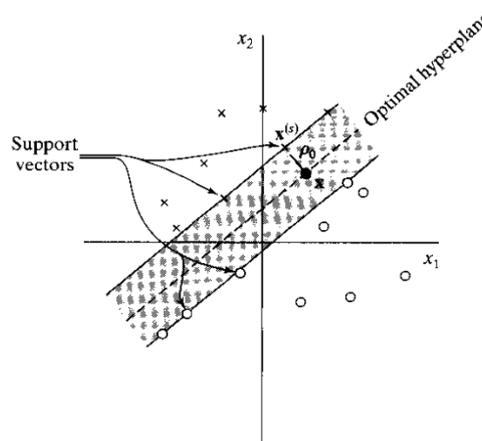
$$\mathbf{w}^T \mathbf{x} + b = 0 \quad (1)$$

onde \mathbf{x} é o vetor de entrada, \mathbf{w} é o vetor de pesos que dá a inclinação da superfície de decisão e b é o *bias*. A classificação é dada por:

$$\begin{aligned} \mathbf{w}^T \mathbf{x}_i + b &\geq 0, & \text{para } d_i = +1 \\ \mathbf{w}^T \mathbf{x}_i + b &\leq 0, & \text{para } d_i = -1 \end{aligned} \quad (2)$$

Para um dado vetor de pesos \mathbf{w} e o *bias* b , a separação entre o hiperplano e o ponto de dados mais próximo é chamado de *margem de separação*. O objetivo da Máquina de Vetor de Suporte é encontrar um hiperplano particular, com a maior *margem de separação* possível, como pode ser visto na Figura 2.

Figura 2 - Hiperplano ótimo e margem de separação.

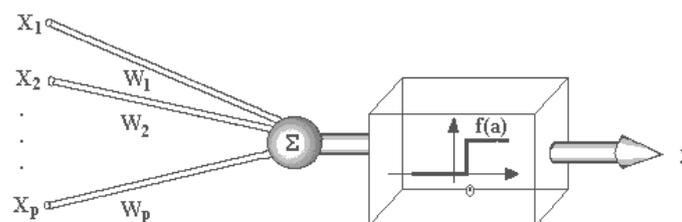


Por sua vez, as Redes Neurais Artificiais, de acordo com ICMC (?), são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência. São compostas por várias unidades de processamento que são conectadas por canais de comunicação que estão associados a determinado peso.

As unidades fazem operações apenas sobre seus dados locais, que são entradas recebidas pelas suas conexões. O comportamento inteligente de uma Rede Neural Artificial vem das interações entre as unidades de processamento da rede.

A operação de uma unidade de processamento, proposta por McCullock e Pitts em 1943, pode ser resumida da seguinte maneira: sinais são apresentados à entrada; cada sinal é multiplicado por um número, ou peso, que indica a sua influência na saída da unidade; é feita a soma ponderada dos sinais que produz um nível de atividade; se este nível de atividade exceder um certo limite (*threshold*) a unidade produz uma determinada resposta de saída.

Figura 3 - Modelo de Mcullock e Pitts.



É notório que toda planta industrial brasileira constitui um grande campo de estudos de eficiência energética, qualidade de energia elétrica e de procedimentos de manutenção preditiva e detectiva. Tal cenário serve de motivação para que, futuramente, os experimentos computacionais propostos neste documento se tornem um sistema protótipo de um monitor de ESA que, ao ser inserido em uma planta industrial, será capaz de contribuir para o diagnóstico precoce de falhas em máquinas elétricas, evitando que o processo produtivo sofra prejuízos com paradas não programadas.

METODOLOGIA:

A base de dados utilizada neste trabalho é proveniente de Hammo (2014), em que foram simuladas as falhas em um motor de indução trifásico, rotor em gaiola, 1/3 hp. Os dados de tensão e de corrente foram obtidos utilizando a plataforma LabVIEW para que fossem criadas as simulações das seguintes faltas: subtensão, sobretensão, desbalanceamento de fase, rotor bloqueado, sobrecarga e falta de fase. Uma vez construída a base de dados, a quantidade disponível de padrões por falta está apresentada na Tabela 1.

Um pequeno trecho desta base de dados está ilustrado na Figura 4, com o seguinte formato:

rótulo atrib1:valor atrib2:valor atrib3:valor atrib4:valor atrib5:valor atrib6:valor
--

onde:

- **rótulo:** valor inteiro correspondente ao tipo de falha;
- **atrib1:** atributo 1 (tensão na fase 1);
- **atrib2:** atributo 2 (tensão na fase 2);
- **atrib3:** atributo 3 (tensão na fase 3);
- **atrib4:** atributo 4 (corrente na fase 1);
- **atrib5:** atributo 5 (corrente na fase 2);
- **atrib6:** atributo 6 (corrente na fase 3).

Tabela 1 - Número de padrões por falha.

Condição	Número de padrões
Sem falha	154
Falta de fase	85
Desbalanceamento de fase	450
Subtensão	49
Sobretensão	10
Rotor bloqueado	10
Sobrecarga	30
Total	788

Fonte: Hammo (2014).

Figura 4 - Trecho da base de dados com as falhas simuladas.

Training Data						
No. of patterns: 788						
No. of inputs: 6						
No. of outputs: 7						
	V1	V2	V3	I1	I2	I3
1	1: 2.661025	2: 2.624276	3: 2.701274	4: 0.4907675	5: 0.478549	6: 0.4933681
1	1: 2.660319	2: 2.624661	3: 2.7007	4: 0.4911136	5: 0.4787216	6: 0.4925841
1	1: 2.658824	2: 2.623414	3: 2.699373	4: 0.4907824	5: 0.4780662	6: 0.4924988
1	1: 2.659359	2: 2.623496	3: 2.700214	4: 0.4909006	5: 0.4778042	6: 0.4928816
1	1: 2.659918	2: 2.624527	3: 2.701876	4: 0.4911553	5: 0.4781739	6: 0.4923389
1	1: 2.660713	2: 2.624278	3: 2.700593	4: 0.4912516	5: 0.4782521	6: 0.4925644
1	1: 2.660079	2: 2.623479	3: 2.699637	4: 0.4908446	5: 0.478162	6: 0.4926641
1	1: 2.65911	2: 2.623836	3: 2.699883	4: 0.4906552	5: 0.4780388	6: 0.4923748
1	1: 2.660678	2: 2.624341	3: 2.70043	4: 0.4913352	5: 0.4774227	6: 0.4927595
1	1: 2.661025	2: 2.624276	3: 2.701274	4: 0.4907675	5: 0.478549	6: 0.4933681

Fonte: Adaptado de Hammo (2014).

Para realizar o treinamento da rede neural, assim como da máquina de vetor de suporte, e o levantamento de seus respectivos desempenhos, esta base de dados foi dividida em um subconjunto de treinamento (80% dos dados) e outro subconjunto de teste (20% dos dados). Como cada instância da base é composta de 6 valores, a rede neural MLP utilizada terá 6 neurônios na camada de entrada. De acordo com a Tabela 1, Hammo (2015) levantou 7 padrões de falha, em que cada um destes padrões está associado com cada uma das instâncias. Sendo assim, a rede neural possuirá 7 neurônios na camada de entrada.

Para obtenção da melhor configuração de rede neural, ou seja, para encontrar a rede que fornece o menor valor de taxa de erro de classificação, foi realizado um *tuning* que consiste em realizar diversos experimentos com o intuito de obter o melhor setup de valores dos parâmetros livres da rede neural. Tais

parâmetros livres são: taxa de aprendizado, número de neurônios da camada escondida e faixa de valores para inicialização dos pesos sinápticos. Como todas as instâncias da base de dados são valores positivos, optou-se por utilizar somente a função de ativação sigmoial.

Por se tratar de um projeto de pesquisa em andamento, os dados de desempenho que serão apresentados neste trabalho se referem apenas à rede neural. A implementação da máquina de vetor de suporte será realizada no segundo semestre de 2018.

RESULTADOS E DISCUSSÕES:

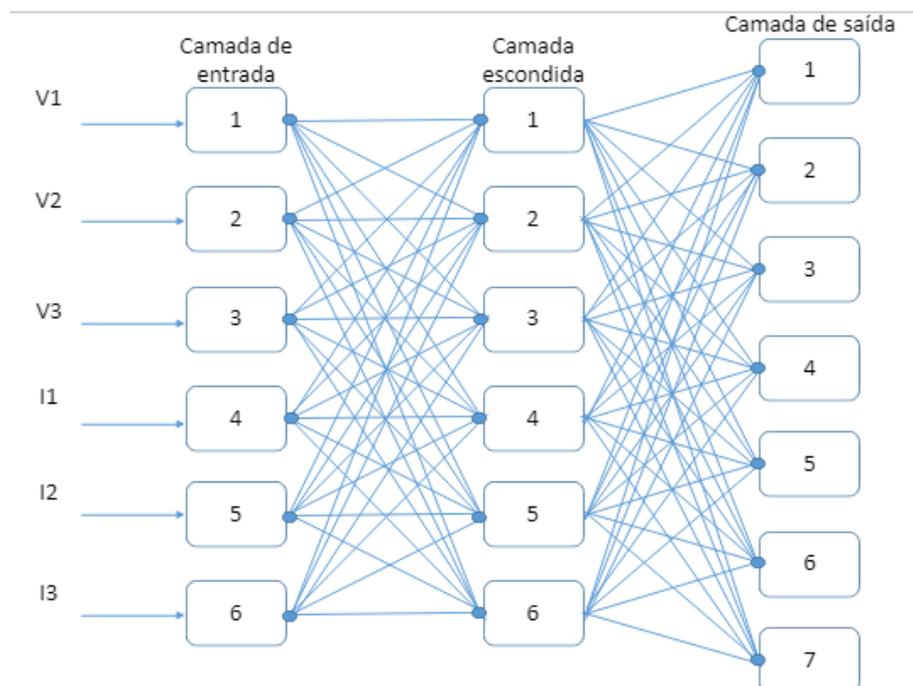
Para a inicialização da rede neural os pesos sinápticos foram gerados aleatoriamente, com intervalo entre $-0,5$ a $0,5$. Por razões da estrutura de dados da base de Hammo (2014), foram necessários 6 neurônios na camada de entrada e 7 neurônios na camada de saída. A rede neural implementada está ilustrada pela Figura 5. Executando a rede neural com a base de dados (Hammo, 2014) com diferentes limiares, obteve-se os seguintes resultados:

Tabela 1 – Resultados da Rede Neural criada.

Passo de aprendizagem	0,1	0,2	0,3	0,4	0,5	0,2	0,3	0,4	0,5
Tolerância	0,1	0,1	0,1	0,1	0,1	0,2	0,2	0,2	0,2
Taxa de acerto com 6 neurônios na cam. escond.	79,69%	87,81%	88,07%	91,12%	81,22%	66,75%	77,92%	80,96%	73,10%
Taxa de acerto com 7 neurônios na cam. escond.	85,79%	90,36%	90,10%	95,18%	91,37%	79,19%	85,53%	84,52%	83,25%

Fonte: O próprio autor (2018).

Figura 5 – Rede Neural MLP criada.



Fonte: O próprio autor (2018).

Pode-se observar que a rede teve uma melhor eficiência com sete neurônios na camada escondida, sendo os testes realizados com um erro aceitável, tendo uma maior taxa de acerto. De acordo com a Tabela 1 os

passos de aprendizagem não são parâmetros lineares no que se diz respeito a taxa de acerto adquirida. Ou seja, um aumento no passo de aprendizagem, não significa necessariamente uma diminuição na taxa de acerto. Porém, sabe-se que quanto maior o passo de aprendizagem maior será a variação nos valores de atualização dos pesos sinápticos, podendo ocasionar em um ponto acima do mínimo local na superfície de erro. Por outro lado, quanto menor o passo de aprendizagem, menor será a atualização observada dos pesos sinápticos. Logo, será necessária uma quantidade maior de iterações para que se chegue no ponto de mínimo local da superfície de erro.

CONCLUSÕES:

Tendo como base os estudos efetuados até aqui, já que até o momento da escrita desse artigo só foram efetuadas pesquisas com redes neurais, sendo possível observar que, conforme mostrado nos resultados da Tabela 1, foram alcançadas taxas de acerto que poderão ser comparadas com o desempenho da máquina de vetor de suporte, para que seja verificada qual a técnica mais adequada para a detecção de falhas do motor de indução trifásico apresentado anteriormente.

Com essa pesquisa, também identifica-se a aplicabilidade de uma rede neural para a detecção de falhas em motores elétricos a partir da técnica de análise por assinatura elétrica, já que, de acordo com os dados coletados é possível observar que cada problema gera um padrão de tensão e de corrente passível de reconhecimento pela rede. Assim, é possível detectar um padrão de falha em tempo real, não havendo necessidade interrupção do funcionamento da máquina elétrica, o que traz uma grande vantagem em uma gama de aplicações. Uma parada não programada de um motor pode trazer várias consequências graves ao processo produtivo, como no caso de uma indústria onde uma falha no motor pode causar uma parada em uma linha inteira de produção.

Por fim espera-se que a máquina de vetor de suporte obtenha um rendimento próximo ou superior a rede neural, podendo assim realizar o comparativo entre os dois métodos de reconhecimento de padrão e analisar o melhor cenário para a detecção de falhas em motores trifásicos.

REFERÊNCIAS BIBLIOGRÁFICAS:

BHATTACHARYYA S. et. al. **Induction motor fault diagnosis by motor current signature analysis and neural network techniques**. 2015. Disponível em: <<https://pdfs.semanticscholar.org/49f1/3ce9e81bb26325fdc72670826f3eca1044f5.pdf>>. Acesso em: 07 fev. 2018.

CORRÊA, S. L. CERQUEIRA, R. F. G. **Diagnóstico de falhas e localização de problemas em sistemas auto-gerenciáveis**. 2008. Disponível em: <http://www.dbd.puc-rio.br/depto_informatica/08_49_correa.pdf>. Acesso em: 10 fev. 2018.

DA SILVA, J. G. B. **Modelagem e tratamento dos sinais da assinatura elétrica de máquinas para melhoria do diagnóstico de falhas**. 2015. Disponível em: <https://www.google.com.br/url?sa=t&rct=j&q=&esrc=s&source=web&cd=6&ved=0ahUKEwi6u47e2qXZAhVDDJAKHZrCAEUQFghQMAU&url=https%3A%2F%2Frepositorio.unifei.edu.br%2Fxmlui%2Fbitstream%2Fhandle%2F123456789%2F431%2Ftese_silva_2015.pdf%3Fsequence%3D1%26isAllowed%3Dy&usg=AOvVa w1XUa58X1px3UDsWj9Th2pi>. Acesso em: 08 fev. 2018.

DEÁK, K. et. al. **Failure diagnosis with SVM in machine learning maintenance engineering**. Disponível em: <<https://imtuoradea.ro/auo.fmte/files-2014-v1/Deak%20Krisztian->

FAILURE%20DIAGNOSTICS%20WITH%20SVM%20IN%20MACHINE%20MAINTENANCE%20ENGINEER
ING.pdf>. Acesso em: 08 fev. 2018.

HAMMO, R. **Faults identification in three-phase induction motors using sport vector machines.** 2014. 90 f. Dissertação (*Master of Technology Management*) - Bowling Green State University, Bowling Green, 2014.

HAYKIN, S. **Redes neurais: teoria e prática.** 2. ed. São Paulo: Bookman, 2007.

ICMC. **Redes neurais artificiais.** ?. Disponível em:
<<http://conteudo.icmc.usp.br/pessoas/andre/research/neural>>. Acesso: em 06 ago. 2018.

MARAN, M. **Manutenção baseada em condição aplicada a um sistema de ar condicionado como requisito para sustentabilidade de edifícios e escritórios.** 2011. Disponível em:
<https://www.google.com.br/url?sa=t&rct=j&q=&esrc=s&source=web&cd=10&ved=0ahUKEwi6u47e2qXZAhVDDJAKHZrCAEUQFghkMAk&url=http%3A%2F%2Fwww.teses.usp.br%2Fteses%2Fdisponiveis%2F3%2F3146%2Fde-12122011-142917%2Fpublico%2FDissertacao_Marcos_Maran.pdf&usg=AOvVaw2rZ-wXFXuTyql2qcBLNd60>. Acesso em: 08 fev. 2018.

MILKOVIC, D. **Brief review of motor current signature analysis.** 2015. Disponível em:
<<https://www.google.com.br/url?sa=t&rct=j&q=&esrc=s&source=web&cd=1&ved=0ahUKEwjA1oTc5KXZAhVJUJAKHWv9BKMqFggsMAA&url=https%3A%2F%2Fhrca.srce.hr%2Ffile%2F218882&usg=AOvVaw0YWhajOzypHdUgKATb1Mw4>>. Acesso em: 11 fev. 2018.

REIS, A. J. S. **Reconhecimento de padrões de falhas em motores trifásicos utilizando redes neurais.** 2010. Disponível em:
<https://repositorio.ufrn.br/jspui/bitstream/123456789/15341/1/AdersonJSR_DISSERT.pdf>. Acesso em: 14 fev. 2018.

RUELA, André Siqueira. **Redes neurais feedforward e backpropagation.** 2012. Disponível em:
<http://www.decom.ufop.br/imobilis/wp-content/uploads/2012/06/03_Feedforward-e-Backpropagation1.pdf>. Acesso em: 08 ago. 2018.

SALEM, S. B. BACHA, K. CHAARI, A. **Support vector machine-based decision for induction motor fault diagnosis using air-gap torque frequency response.** 2012. Disponível em:
<<http://research.ijcaonline.org/volume38/number5/pxc3876812.pdf>>. Acesso em: 08 fev. 2018.

SILVA, IVAN, SPATI, DANILO, FLAUZINO, ROGÉRIO. **Redes Neurais Artificiais para engenharia e ciências aplicadas.** 1. ed. São Paulo: Artliber, 2010.

SILVER, DAVID. **Perceptrons and Self-Driving Cars | Learning Self-Driving Cars on BackLine. Readbackline.com.** Disponível em: <<https://readbackline.com/self-driving-cars/perceptrons-and-self-driving-cars-9v59m6e2/>>. Acesso em: 08 ago. 2018.