

Diagnóstico de falhas em sistemas degradados utilizando técnicas de Redes Neurais Artificiais

Ricardo de Carvalho Destro
Volans Informática Ltda
Centro Universitário da FEI
04548-005, São Paulo, São Paulo, Brasil
ricardo.destro@volans.com.br

Mariana Antonia Aguiar
Centro Universitário das Faculdades Metropolitanas Unidas – UniFMU/FISP
Volans Informática Ltda
04548-005, São Paulo, São Paulo, Brasil
mariana.aguiar@fisp.br

Rogério Akira Furucho
Centro Universitário das Faculdades Metropolitanas Unidas – UniFMU/FISP
Volans Informática Ltda
04548-005, São Paulo, São Paulo, Brasil
rogerio.akira@fisp.br

Resumo

Um dos principais problemas enfrentados pelas empresas que utilizam equipamentos de automação bancária e comercial é aumentar ou manter a disponibilidade dos mesmos e reduzir o seu custo de manutenção. Atualmente, os equipamentos de automação possuem como recursos módulos de diagnósticos que auxiliam os técnicos em sua tomada de decisão, porém esses módulos são geralmente construídos sobre códigos de erros que mapeiam problemas pontuais (*troubleshooting*), sem levar em consideração a síndrome apresentada. Neste trabalho é apresentado o desenvolvimento e o desempenho de uma Rede Neural Artificial (RNA) para a identificação de falhas em equipamentos que apresentam como síndrome a degradação de seus componentes. Para isso, o algoritmo de Levenberg-Marquardt é utilizado visando agilizar o processo de treinamento da Rede implementada, demonstrando-se totalmente adequado a este tipo de aplicação. Os resultados apresentados mostram que a abordagem aqui descrita é viável para a detecção de falhas em equipamentos eletro-eletrônicos, fornecendo erros de identificação inferiores a 3%.

Palavras-chaves: diagnóstico de falhas; Redes Neurais Artificiais; Backpropagation, Levenberg-Marquardt, automação bancária

Introdução ao Problema Diagnóstico

São bem conhecidos e largamente utilizados os resultados dos modelos de confiabilidade de equipamentos eletro-eletrônicos baseados na premissa de que estes possuem taxa de falhas constante [1].

A detecção de falhas neste tipo de equipamento pode ser feita através da utilização de um limiar de decisão onde, a partir do momento em que a taxa de falhas está acima deste limiar, há a necessidade de uma intervenção de manutenção.

Também é conhecida a ineficácia deste tipo de modelagem em diversos sistemas, principalmente os que apresentam um comportamento degradado antes da efetiva falha.

Equipamentos que apresentam desgaste em seus componentes tendem a apresentar um aumento em sua taxa de falhas. Um caso típico

em que este cenário se faz presente são equipamentos utilizados na automação bancária e comercial, como leitura de cartões magnéticos ou sistemas que dependem de posicionamento por motores. Nestes tipos de equipamentos podem ser utilizadas técnicas para diagnóstico de falhas, cuja definição utilizada neste trabalho pode ser encontrada em Peláez [2] sendo “o processo de identificação da origem da falha após a mesma ter ocorrido”.

Naturalmente, sistemas com características de degradação não apresentam impeditivos para que sejam modelados, sendo que as curvas de Weibull são largamente utilizadas em confiabilidade neste tipo de cenário [1].

Supondo a taxa de falhas descrita pela função $\lambda(t)$:

$$\lambda(t) = \beta \cdot \mu^\beta \cdot t^{\beta-1} \quad (1)$$

O parâmetro β também é conhecido como parâmetro de forma, e μ , parâmetro de escala e t o tempo do sistema. Desta equação, que na verdade representa um processo de Poisson, pode-se notar que a taxa de falhas constante é na verdade um caso particular, onde $\beta=1$. A Figura 1 mostra a variação da forma de $\lambda(t)$ com a variação de β , mantendo-se o parâmetro de escala $\mu=0.01$. Valores de β maiores que 1 indicam taxa de falhas crescente, enquanto valores menores que 1 taxas decrescentes.

Naturalmente, não são comuns equipamentos que apresentam taxa de falhas decrescente. No entanto este fenômeno pode ser observado em equipamentos que passaram por programas de manutenção preventiva.




Figura 1: Variação de λ em função dos valores do parâmetro β . Neste trabalho são analisados equipamento com $\beta > 1$.

Para equipamentos que apresentam valores de β maiores que 1, como leitores de cartão magnético devido ao desgaste da cabeça de leitura magnética, a detecção de defeitos pode ser realizada de forma simples, bastando-se estabelecer um limite aceitável para a quantidade de eventos de falha observados. Esta abordagem somente é possível se os equipamentos em análise não sofrerem a interferência de agentes externos que possam desencadear a ocorrência de falhas similares, simplificando a construção do modelo analítico[3].


Neste presente trabalho, adotam-se os conceitos de Sistema Normal ou sem falhas, Sistema Degradado, quando apresenta falhas parciais ou em algumas de suas funções e Sistema Inoperante ou totalmente falho, quando o equipamento não mais consegue desempenhar as funções ao qual foi projetado [2].

Falhas ocasionadas por agentes externos não estão relacionadas a um problema no equipamento, mas sim ao seu ambiente de utilização. No entanto, para o caso em estudo, elas se manifestam como se um problema funcional estivesse presente e um sistema para


o diagnóstico de falhas deve ser capaz de identificar quando uma sequência de falhas é proveniente de um defeito ou problema no equipamento ou do ambiente.

Como exemplo desta interferência, o leitor de cartões é fortemente sensível à qualidade das tarjas magnéticas, pois as mesmas quando apresentam-se muito desgastadas exigem que a cabeça leitora esteja em condição de operação próximas do ideal para que a falha de leitura não seja observada. Outro exemplo é o sistema de posicionamento baseado em motor que está sujeito ao bloqueio do seu curso de trabalho por inserção de objetos em seu trajeto ou por falta de lubrificação de seus trilhos cursores, ocasionando uma falha de posicionamento, sem que haja efetivamente um problema funcional no equipamento.

A Figura 2 apresenta os eventos de falha em um sistema com as características para um equipamento de leitora de cartões magnéticos utilizados em sistemas de automação bancária.



(a)



(b)

Figura 2: (a) Evolução de eventos de falhas em equipamento de leitora de cartão magnético no início de sua vida útil e (b) após um processo de degradação de seus componentes

É claramente observável a evolução da taxa de falhas neste tipo de equipamento, na Figura 2 (a), que apresenta poucos eventos de falha no início da sua vida útil, e na Figura 2 (b) onde estes eventos se acumulam com o passar do

tempo, culminado em uma seqüência de erros operacionais que inviabilizam ou impossibilitam sua utilização.

Identificar, baseando-se no padrão de ocorrência de falhas, a origem das mesmas (se é realmente uma falha no hardware ou se o problema é na trilha magnética dos cartões) é uma das tarefas que pode auxiliar no aumento da disponibilidade do equipamento, uma vez que permite sua manutenção preditiva e o melhor planejamento de intervenções de reparação, reposições e substituições de suas peças.

Aplicação de RNA para Diagnóstico em Sistema de Leitora de Cartões Magnéticos

Para a solução do problema proposto utilizando-se RNA é necessária a modelagem e construção de uma base de dados capaz de representar a diferença no comportamento deste tipo de equipamento em funcionamento normal e em funcionamento degradado, apresentando-a para a fase de treinamento da rede.

Assim, é necessária a coleta de dados operacionais do sistema em análise. Esta coleta deve ocorrer sobre uma população controlada a fim de permitir um maior grau de rastreabilidade das informações e evitar a contaminação dos dados com informações incorretas ou imprecisas.

Para esta base deve-se evitar principalmente a contaminação dos dados por utilização de registros de equipamentos que apresentam algum tipo de problema relacionado a seu processo de fabricação e não a sua utilização. Este tipo de problema pode ser detectado em testes de burn-in[3], mas a recomendação é sempre averiguar os dados coletados sendo que se detectado este tipo de contaminação, seus respectivos registros devem ser retirados da base.

A. Dados de Entrada

Para a análise do desempenho desta solução, selecionou-se duas bases de dados Ψ_1 e Ψ_2 , ambas com os cem últimos eventos de falha em uma leitora de cartões, sendo que Ψ_1 armazena os eventos de falha de uma população de 1000 indivíduos com comportamento degradado e Ψ_2 , registros de 1000 indivíduos com comportamento não degradado para o parâmetro em estudo. Estas duas bases foram agrupadas em uma base de dados Ψ , construída como uma matriz de dimensões 100x2000, que foi utilizada para o treinamento da RNA.

O comportamento de cada indivíduo é composto de um vetor de dimensão igual à quantidade de falhas armazenadas (ou seja,

100) cujos valores são indicativos da ordem da operação em que o evento de falha ocorreu sendo, portanto, estritamente crescente. Por exemplo, um determinado indivíduo possui o seu comportamento descrito pelo vetor [263;6374;...;172839;172951], que indica a última falha ocorrida na 172.951ª operação e a primeira falha armazenada ocorrida na 263ª.

Devido a grande dimensão dos vetores de entrada armazenados, optou-se por reduzi-la através da Análise de Componentes Principais (PCA) [8][6], para extrair deste conjunto apenas as informações realmente relevantes e não exigir que a RNA se adapte a todas as pequenas nuances da base de dados.

Basicamente, a PCA é realizada através da determinação de um vetor de codificação Q que é aplicado a cada um dos vetores que compõem a base de dados normalizada Ψ_n a fim de reduzir a dimensão dos seus vetores.

A aplicação da PCA reduziu a dimensão de cada vetor de 100 componentes para apenas doze, mantendo 99,9% das informações.

Em seguida, a base Ψ_n codificada é novamente multiplicada pelo vetor de decodificação Q_t para se obter apenas as componentes mais significativas de Ψ_n , obtendo-se assim a base final de entrada Ψ_{in} .

Após a etapa da PCA, a base de dados Ψ_{in} foi dividida em três conjuntos: um de treinamento Ψ_{tr} , com aproximadamente 60% dos indivíduos, um de teste Ψ_{tt} e outro de validação Ψ_{vd} .

Como etapa final, tem-se o conjunto dos vetores de saída ou target Φ , com dimensão 1x2000. Para cada vetor de entrada da base Ψ_1 é associado o valor 1 na correspondente componente de Φ . Para os vetores de Ψ_2 , o valor associado em Φ é zero.

B. Arquitetura da Rede Utilizada

Para a solução deste problema optou-se pela utilização de uma rede de perceptrons multicamada (MLP), contendo uma camada intermediária e um neurônio na camada de saída, conforme a Figura 3




Figura 3: Arquitetura MLP com uma camada intermediária e um neurônio na saída

Além disso, foram testados dois algoritmos de treinamento que utilizam a técnica da retropropagação de erros (backpropagation).

O primeiro deles, da forma clássica como proposto em [11] e largamente utilizado, baseado no gradiente da superfície de erros [2][8][10]. O segundo algoritmo testado, que apresentou os melhores resultados, foi o algoritmo de Levenberg-Marquardt[5].

Este algoritmo foi apresentado por Marquardt em 1963 para a estimação de parâmetros não lineares e é utilizado devido a sua ótima velocidade de treinamento quando satisfeitas suas restrições de uso [4].

O treinamento foi feito através de uma aproximação do Hessiano (H) de seu conjunto de dados Ψ_{tr} pelo produto de Jacobianos (J) deste mesmo conjunto, como pode ser visto em (2).

$$H = J^t \cdot J \quad (2)$$

A atualização dos pesos durante o treinamento da rede pode ser feito através da equação (3), bastante similar ao método de Newton para estimação de parâmetros. Nesta equação, tem-se x_{k+1} sendo o elemento na próxima iteração, x_k o atual valor do elemento, η é a taxa de treinamento da rede e e , o erro quadrático médio do problema.

$$x_{k+1} = x_k - [J^t \cdot J + \eta \cdot I]^{-1} \cdot J^t \cdot e \quad (3)$$

O gradiente é obtido em (3) a partir do termo $J^t \cdot e$. Quando o parâmetro η é igual a zero, a equação (3) é idêntica ao método de Newton, observada na matriz H observada na equação (2). O termo $\eta \cdot I$ foi acrescentado em (3) para assegurar que a matriz $(J^t \cdot J + \eta \cdot I)$ seja positiva e definida para qualquer dimensão dos vetores de entrada.

Como o método de Newton converge otimamente quando o erro é pequeno, busca-se diminuir η com a evolução do treinamento para aproximar-se da solução desejada.

A principal restrição ao uso deste algoritmo é a utilização intensiva de memória do computador durante a fase de treinamento, o que limita sua aplicação a redes pequenas, normalmente apresentando algumas centenas de pesos a serem ajustados. No entanto, uma solução possível é utilizar parte da matriz J carregada na memória, determinando-se H por partes e fazendo com que a memória alocada seja diminuída. Entretanto, constatou-se durante os ensaios deste problema que o treinamento de redes com uma quantidade maior que 30 neurônios causa uma grande perda de desempenho do computador e faz com que o

treinamento se estenda por um tempo muito longo, quando comparado com redes menores.

C. Formato da Saída

A camada de saída da RNA utilizou um neurônio com a tangente hiperbólica como função de transferência, fornecendo, portanto, uma saída no intervalo [-1,1].

A saída da rede foi aplicada, após o treinamento, uma função degrau, que informa o limiar a ser utilizado para a seleção da classificação de um indivíduo como falho ou não. Esta função degrau ajusta os valores de saída para 0 (menor que o limiar) ou 1 (maior que o mesmo), permitindo uma comparação direta entre os conjuntos Φ_s , de saída da rede, e Φ de target.

A Figura 4 mostra a arquitetura final da RNA.




Figura 4: Arquitetura final da RNA utilizada com função degrau na camada de saída

Dois resultados merecem atenção especial: o que sinaliza um Falso Alarme (FA) e o que sinaliza uma Perda de Diagnóstico (PD).

O FA ocorre nos casos em que Φ_s é igual a 1 e o correspondente componente de Φ igual a 0, ou seja, a RNA estaria classificando o equipamento como degradado quando na verdade o mesmo não apresenta aumento da taxa de falhas. Esta situação de falso positivo pode ocorrer quando o equipamento está excessivamente sensível aos parâmetros de ambiente ou quando as falhas são geradas por outro problema que não o em análise (interferência externa).

Para a situação oposta, quando Φ_s é igual a 0 e Φ igual a 1, temos caracterizado um evento de Perda de Diagnóstico, ou seja, a RNA não está conseguindo identificar um equipamento que apresenta sintomas de degradação.

O ajuste do limiar da função degrau é o responsável por determinar os níveis de Falso Alarme e Perda aceitáveis para cada equipamento avaliado. Dependendo do tipo de aplicação em que o equipamento é utilizado, pode ser conveniente permitir um Falso Alarme elevado, mediante a possibilidade de perder uma situação de falha e, como consequência, aumentando seu índice de indisponibilidade.

Esta situação pode ocorrer quando o acesso ao equipamento para manutenção é fácil porém

sua rotina de manutenção é muito extensa ou sua indisponibilidade por períodos longos pode trazer sérios prejuízos à operação.

Resultados Obtidos

Buscou-se encontrar um conjunto de parâmetros que oferecesse a melhor saída para os dados de treinamento e validação, a fim de assegurar o poder de generalização da arquitetura testada.

A Figura 5 apresenta os resultados para o treinamento desta arquitetura utilizando o algoritmo clássico de backpropagation com 10 neurônios na camada intermediária.

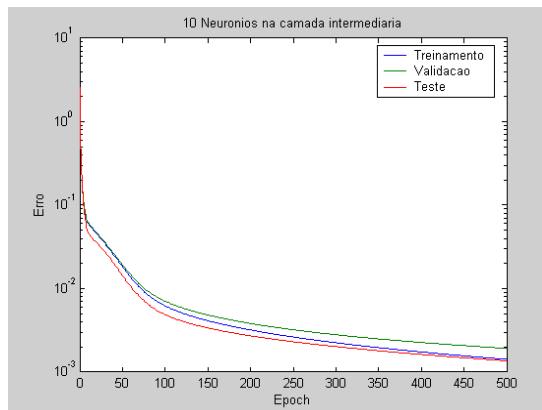


Figura 5: Resultado do treinamento da RNA MLP com 10 neurônios na camada oculta

O Quadro 1 apresenta os resultados dos ensaios com variação do número de neurônios da camada oculta. Este quadro mostra a arquitetura de 6 neurônios como possuindo o menor erro quadrático médio. Entretanto, os resultados apresentados na validação não foram satisfatórios. Para este cenário, a arquitetura escolhida foi a de quatro neurônios na camada intermediária, que apresentou um resultado satisfatório, dentre os analisados, para os conjuntos de treinamento e validação.

Quadro 1: Resultado do treinamento da RNA MLP utilizando algoritmo de treinamento backpropagation clássico em função da quantidade de neurônios na camada oculta e do Erro Médio Quadrático (MSE)

Qte. neurônio camada oculta	Iterações (épocas)	MSE ($\cdot 10^{-3}$)		
		Treina-mento	Testes	Valida-ção
4	438	0,6562	0,55443	0,82953
5	500	1,7766	1,60440	1,69100
6	500	0,6124	0,44853	1,06060
7	332	0,9054	0,85356	1,25820
8	422	1,4003	2,04560	1,65340
9	500	2,4264	3,02160	3,95050
10	500	10,921	12,7320	13,1120

No entanto, os melhores resultados foram obtidos utilizando-se uma RNA MLP utilizando o algoritmo de treinamento de Levenberg-Marquardt, como mostrado na Figura 6.

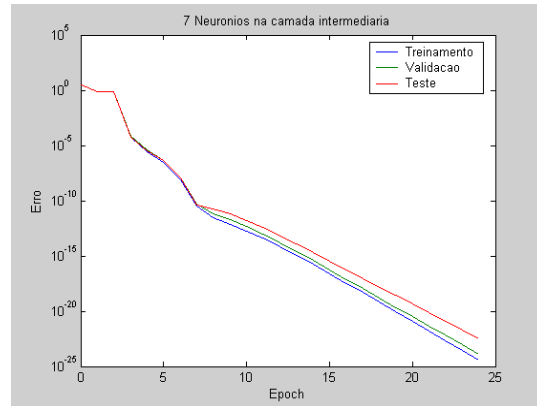


Figura 6: Resultado do treinamento da RNA MLP com algoritmo de treinamento Levenberg-Marquardt

O Quadro 2 apresenta um resumo dos ensaios com os melhores desempenho sobre os dados disponíveis.

Quadro 2: Resultado do treinamento utilizando Levenberg-Marquardt em função da quantidade de neurônios da camada intermediária em função da quantidade de neurônios na camada oculta e do Erro Médio Quadrático (MSE)

Qte. neurônio camada oculta	Iterações (épocas)	MSE ($\cdot 10^{-26}$)		
		Treina-mento	Testes	Valida-ção
2	228	23,6420	723,73	15010
3	327	0,7641	6,0609	11,911
4	172	1,2554	11,398	28,974
5	128	0,6070	0,7422	0,7318
7	24	10,1862	30,2475	50,4813
10	137	38,9260	627,10	8508,0

Estes resultados mostram que o algoritmo de treinamento de Levenberg-Marquardt possui melhor desempenho do que a abordagem clássica analisada anteriormente, sendo a arquitetura com 5 neurônios na camada oculta a que apresentou os melhores resultados.

Quadro 3: Percentuais de Perdas e Falsos Alarmes obtidos sobre o conjunto de testes dado um determinado limiar de decisão

Limiar	Erro (%)		
	Perda	Falso Alarme	Total
-0,4	0,4	16,0	16,4
-0,2	0,8	11,7	12,5
0,0	1,0	5,3	6,3
0,2	1,3	1,4	2,7
0,4	6,8	1,1	7,9

Aplicando-se a rede de melhor desempenho, com cinco neurônios na camada oculta,

algoritmo de treinamento Levenberg-Marquardt, a um conjunto de dados inéditos, retirados de uma população com 100 indivíduos, degradados ou não, obteve-se os resultados apresentados no Quadro 3.

Estes resultados demonstram que, utilizando-se um limiar de 0,2 na saída, é possível classificar os padrões de entrada com um erro inferior a 3%, o que assegura um bom desempenho para a rede. Além disso, os erros devido a Falso Alarme e Perda de Diagnóstico são praticamente equivalentes quando utilizado este limiar de 0,2.

Conclusões

Os resultados apresentados demonstram que a aplicação de RNA para a detecção de falhas em equipamentos com sintomas de degradação é altamente satisfatória.

A utilização do algoritmo de Levenberg-Marquardt para o treinamento da rede demonstrou que é possível atingir-se resultados satisfatórios sem comprometer o tempo disponível ou o desempenho do sistema computacional empregado. Este fato pode ser especialmente útil em sistemas que devem ser atualizados freqüentemente ou sistemas em que se pretenda embarcar a capacidade de adaptação do sistema diagnóstico.

Os próximos passos deste trabalho será a comparação de resultados com outras técnicas de análise, como a utilização de janelamento dos dados com aplicação de média móvel e limiar de decisão e também a aplicação destas abordagens de diagnósticos para identificação preditiva de falhas em leitores de cartões magnéticos que não podem sofrer manutenção em campo e, embora apresente custo de compra relativamente baixo, podem levar todo o equipamento de auto-atendimento a um estado de não operação.

Além disso, a identificação de falhas em equipamentos com degradação permite uma otimização em suas políticas de manutenção preditiva, aumentando seu retorno financeiro e seus índices de disponibilidade.

Referências

- [1] Kales, P. Reliability for technology, Engineering, and Management Prentice Hall, 1998.
- [2] Peláez, J.R. et. Al. Predictive maintenance oriented neural network system – PREMON. Proceedings of the 27th Annual Conference of the IEEE Industrial Electronics Society, 2001.
- [3] Kapur, K. C.; Lamberson, L. R. Reliability in engineering design, John Wiley & Sons, Inc, 1977.
- [4] Marquardt, D.W. An algorithm for least-squares estimation of non-linear parameters. Journal of the Society of Industrial and Applied Mathematics 11 (2), p.431-441, 1963.
- [5] Hagan, M. T.; Menhaj, M. Training feedforward networks with the Marquardt algorithm. IEEE Transactions on Neural Networks, vol. 5, no. 6, pp. 989-993, 1994.
- [6] Bishop, C. Neural Networks for Pattern Recognition. Oxford: University Press, 1995.
- [7] Prechelt, L. A quantitative study of experimental neural network learning algorithm evaluation practices. Technical Report 1995.
- [8] Haykin, S. Neural Networks: a comprehensive foundation. 2nd ed. Prentice-Hall, 1998.
- [9] Jain, A.K. et all. Statistical Pattern recognition: a review. IEEE Transactions on Pattern Analysis and Machine Intelligence, 22(1):4-37, 2000.
- [10] Kovács, Z.L. Redes Neurais Artificiais – Fundamentos e Aplicações 3º edição Editora Livraria da Física, 2002.
- [11] McClelland, J.L.; Rumelhart, D.E. Explorations in parallel distributed processing. MIT Press, 1988.