

MAPA DE CARACTERÍSTICAS AUTO-ORGANIZÁVEIS APLICADO AO DIAGNÓSTICO DE FALHAS EM EQUIPAMENTOS DE AUTOMAÇÃO BANCÁRIA

MARIANA ANTONIA AGUIAR-FURUCHO

*Departamento Acadêmico de Eletrotécnica - DAELT, Universidade Tecnológica Federal do Paraná - UTFPR
Av. Sete de Setembro, 3165, Rebouças, Curitiba, PR, CEP 80230-901
E-mail: marianafurucho@utfpr.edu.br*

ROGERIO AKIRA FURUCHO

*Diretoria de Elétrica - DEL, Instituto Federal de Educação, Ciência e Tecnologia de São Paulo - IFSP
Rua Pedro Vicente, 625 - Canindé, SP, CEP 01109-010
E-mail: rogerio.akira@ifsp.edu.br*

RICARDO DE CARVALHO DESTRO

*Departamento de Engenharia Elétrica, Centro Universitário da Fundação Educacional Inaciana "Padre Sabóia de Medeiros" - FEI
Av. Humberto de Alencar Castelo Branco, 3972, São Bernardo do Campo, SP, CEP 09850-90
E-mail: destro@fei.edu.br*

Abstract— This work introduces concepts related to the diagnosis of failures for banking self-service equipment, particularly magnetic card readers, using a data treatment methodology that uses Gaussian convolution as a low-pass filter in order to prepare the data for the application of the network called self-organizing features of Kohonen. The obtained results were compared with the application of another architecture of artificial neural networks and demonstrated that the solution proposed in this work is extremely satisfactory.

Keywords— Fault Diagnostics, Gaussian Convolution, Self-Organizing Map, Predictive Maintenance.

Resumo— Este trabalho introduz conceitos relacionados ao diagnóstico de falhas para equipamentos de autoatendimento bancário, particularmente leitoras de cartões magnéticos, utilizando uma metodologia de tratamento de dados que utiliza convolução gaussiana como filtro passa-baixa de forma a preparar os dados para aplicação da rede denominada mapa de características auto-organizáveis de Kohonen. Os resultados obtidos foram comparados com a aplicação de outra arquitetura de redes neurais artificiais e demonstrado que a solução proposta neste trabalho é extremamente satisfatória.

Palavras-chave— Diagnóstico de falhas, Convolução gaussiana, Mapa Auto-Organizáveis, Manutenção preditiva.

1 Introdução

Nas últimas décadas, o mercado observou uma preocupação crescente sobre a qualidade dos bens e serviços a serem disponibilizados aos consumidores de vários segmentos. Essa tendência, motivada principalmente pela intensificação da concorrência e por clientes mais exigentes, tem demandado aumento de produtividade, confiabilidade e disponibilidade de equipamentos e processos, e redução de custos de operação e manutenção. Avanços técnicos e científicos, caracterizadas pelas inovações tecnológicas em computadores, sensores e em comunicações via internet, entre outras, têm tornado os sistemas de controle e automação de processos cada vez mais complexos (Hines, Miller and Hajek, 1996). Nesse contexto, as estratégias tradicionais de manutenção e de gestão de ativos tornam-se ineficientes e obsoletas, exigindo que as empresas implementem sistemas de monitoramento e controle de equipamentos e processos mais eficientes. Isso é

ainda mais preocupante em setores críticos nos quais a confiabilidade e a disponibilidade dos sistemas e processos são fatores críticos de sucesso, como o setor bancário, aeroespacial, energia entre outros.

No setor bancário, em particular, as instituições têm investido extensivamente em tecnologias que possibilite a redução de custos operacionais e de manutenção e melhore a experiência do usuário (*User Experience*, UX) através da integração de múltiplos canais de atendimento e do aumento da disponibilidade de máquinas de autoatendimento bancário (*Automatic Teller Machines*, ATMs), que se torna uma vantagem competitiva para as empresas do setor bancário (Aguilar et al, 2006). Essas melhorias tecnológicas permitem ainda a oferta de serviços financeiros de forma contínua e em tempo real, resultando em incremento do número de transações efetuadas e do volume financeiro dos bancos.

Considerando a disponibilidade dos equipamentos, qualquer sistema por mais robusto e tolerante a falhas que seja, está sujeito a situações de mau funcionamento, seja devido ao processo natural

de desgaste de seus componentes ou a eventos decorrentes de fatores externos como surtos de tensão. Falhas e defeitos constituem problemas críticos para a operação dos equipamentos que podem comprometer seu funcionamento a ponto de inviabilizar o seu uso e resultar em danos operacionais, prejuízos econômicos e riscos de segurança.

Neste cenário, a manutenção preditiva proporcionada, em particular, pelos sistemas automáticos de detecção, diagnóstico e correção de falhas e defeitos (*Fault Detection, Diagnosis and Correction*, FDDC) tem adquirido maior relevância, sendo objeto de estudo de pesquisadores e profissionais da indústria (Aguiar et al, 2006). Um sistema automático de FDDC avalia os estados (condições) dos componentes de um equipamento de forma contínua e em tempo real e identifica os dispositivos com falhas e defeitos, contribuindo para o diagnóstico e correção por parte do operador (Pelaez et al, 2001), resultando em redução de trocas desnecessárias de dispositivos, de tempo de diagnóstico e custo de manutenção, do número de erros e chamados da assistência técnica e do aumento de confiabilidade e disponibilidade operacional dos dispositivos (Aguiar, 2001; Da Silva Filho, Aguiar and Kovács, 2005).

Vários pesquisadores têm estudado a detecção, diagnóstico e correção de falhas em distintos domínios e aplicações destacando-se, entre elas, as abordagens não clássicas como redes neurais artificiais (*Artificial Neural Networks*, ANN) (Leonard & Kramer, 1993; Pelaez et al, 2001; Aguiar et al, 2006; Da Silva Filho et al, 2005), sistemas imunológicos artificiais (*Artificial Immune Systems*, AIS) (Destro & Bianchi, 2013), autômatos de estado finito e redes de Petri (Cabasino, 2009).

Embora a grande quantidade de pesquisadores e a variabilidade de técnicas empregadas ressaltem a importância e aplicabilidade dos sistemas preditivos automáticos de FDDC, o estudo e análise de diagnóstico de falhas em ATMs utilizando mapa de características auto-organizáveis (*Self-Organizing Feature Map*, SOFM) de Kohonen mostra-se ainda uma abordagem inovadora que utiliza as características da técnica, como redução de dimensionalidade de amostras, agrupamento (*clustering*) e classificação, em benefício do diagnóstico assertivo.

Assim, este trabalho de pesquisa apresenta o estudo e desenvolvimento de uma metodologia baseada no SOFM para diagnóstico de falhas do módulo Leitora de Cartões Magnéticos (LCM), componente presente e indispensável nas ATMs. O desempenho da técnica é avaliado, comparativamente, com o desempenho obtido em Destro, Aguiar & Furuchio (2010) que utilizaram rede de perceptrons multicamada (*Multi-layer Perceptron*, MLP).

2 O Problema Diagnóstico

A confiabilidade e disponibilidade de equipamentos, parâmetros essenciais em sistemas de controle (Goble, 1998), compõem atualmente a principal métrica de processos industriais e sistemas empresariais complexos. Isso se deve especialmente ao fato de que as perdas geradas pelas falhas desses sistemas podem ser significativas, ou mesmo irreversíveis, impactando aspectos como custos, riscos, qualidade dos produtos e serviços, integridade de sistemas e estruturas, segurança de pessoal e equipamentos, entre outros.

2.1 Confiabilidade e Disponibilidade

De acordo com a Norma Brasileira NR-5462/1994 da Associação Brasileira de Normas Técnicas (ABNT), “a confiabilidade consiste na capacidade de um item desempenhar uma função requerida sob condições especificadas, durante um dado intervalo de tempo”. A norma alemã VDI 4001 (1998) explicita que a confiabilidade está relacionada à falha de um item sob determinadas condições de uso e do ambiente durante um dado período de tempo.

A disponibilidade, por sua vez, é a capacidade de um item estar em condições de executar certa função em um dado instante, isto é, a percentagem de tempo em que um equipamento está disponível para exercer a sua função, excluindo o tempo em que esteve parado para manutenção ou por outro motivo qualquer.

2.2 Conceitos de falhas e defeitos

As principais ameaças à confiabilidade, disponibilidade e segurança de sistemas são as falhas, erros e defeitos (Avizienis et al, 2004).

Segundo a IEC 61511 (2003), falha é uma condição anormal de operação de um sistema ou de um de seus elementos que pode causar uma redução ou perda de sua capacidade de executar as funções ao qual foi concebido. A falha é um evento, que pode ser seguida ou não de uma condição de pane e não implica necessariamente na produção de um erro.

Enquanto erro é um resultado incorreto, ou seja, fora da especificação, produzido por um sistema ou por um de seus itens, o defeito é uma alteração que modifica ou incapacita a execução das funcionalidades de um sistema (Aguiar et al, 2006). A causa inicial do defeito está na falha (Johnson, 1989; Avizienis et al, 2004).

Conforme Pelaez et al (2001), os sistemas podem ser classificados em: normal (sem falhas), degradado (quando exibem falhas parciais ou em algumas de suas funções) e inoperante (quando o dispositivo não é capaz de desempenhar suas funções adequadamente conforme o projetado).

2.2 Tipos de falhas

De acordo com a NBR5462/1994, as falhas podem ser classificadas em: primária, secundária, aleatória, por deterioração e crítica. A falha primária, também chamada falha básica, é causada por defeitos de projeto, fabricação e montagem, uso inadequado ou excessivo do equipamento, e falta ou erros de manutenção. A secundária possui como origem a falha primária de outro dispositivo e, por esse motivo, é uma falha que pode ser evitada se a primeira for corretamente solucionada. A aleatória se caracteriza pela imprevisibilidade do instante de ocorrência, sendo possível apenas sua caracterização em termos probabilísticos. A falha por deterioração resulta do processo de desgaste do dispositivo sendo crescente sua taxa de falha instantânea em função do tempo. E, finalmente, a falha crítica está associada a risco de magnitude não aceitável que pode resultar em condições inseguras para pessoas, danos materiais significativos, prejuízos operacionais, danos ao meio ambiente ou outras consequências inaceitáveis.

As falhas também podem ser qualificadas em fatais, que deixam o equipamento inoperante até que haja o reparo do sistema ou recuperáveis, e recuperável, quando o sistema continua funcionando, mas, em geral, de modo degradado até que reparos sejam feitos. Essas falhas podem ocorrer por causa de desgaste de peças, peças defeituosas, sensores defeituosos ou sujos, alimentação de tensão e/ou corrente inadequada além de fatores externos como má operação do equipamento ou problemas provocados em módulos que possuam comunicação com o exterior.

Outra diferenciação possível é entre falhas abruptas e falhas incipientes. Falhas abruptas são aquelas que ocorrem inesperadamente, geralmente ocasionando a parada do equipamento, sem uma causa sistemática anterior que indicasse sua possível ocorrência. Como exemplo, pode-se citar uma falha provocada por uma queima de fusível em uma placa de controle. Em contrapartida, falhas incipientes são aquelas que apresentam uma degradação sistemática durante o tempo de operação do sistema, resultando em um desvio de sua condição normal, o que, no entanto, não ocasiona a parada do equipamento até que esse desvio não atinja um nível que resulte em um desempenho inadmissível do sistema.

Falhas abruptas em sistemas complexos são difíceis de serem detectadas e, por isso, um projeto de FDDC deve considerar duas questões importantes: a rapidez na detecção e a sensibilidade a certos efeitos de altas frequências. Primeiramente, a rapidez da detecção deve ser um fator considerável pois em sistemas de alto desempenho, a falta de agilidade na detecção significa um atraso ao seu retorno à operação normal, diminuindo sua disponibilidade. A segunda questão é que um sistema de FDDC que responda rapidamente a falhas abruptas deve ser necessariamente sensível a certos efeitos de altas frequências, o que o tornará também sensível a ruídos,

podendo gerar falsos alarmes, que são sinalizações de uma falha quando a mesma não está presente.

2.3 Sistema de Diagnóstico de Falhas

A aplicação de conceitos e técnicas da engenharia de sistemas, em particular da engenharia de confiabilidade, são essenciais ao projeto, à operação e à manutenção de sistemas. A engenharia de confiabilidade é uma área da engenharia de sistemas que desenvolve e executa ações com foco na modelagem e análise, predição e otimização da confiabilidade, considerando aspectos ambientais e operacionais como a prevenção, tolerância, correção, predição, detecção e diagnóstico de falhas.

Os sistemas FDDC são o resultado do emprego de vários métodos combinados que, graças aos avanços nas modelagens matemáticas e computacionais e uso de técnicas de inteligência artificial, possibilitam que as estimativas de estados e a identificação de parâmetros dos sistemas sejam implementados em tempo real e com alto índice de assertividade.

As funções de um sistema FDDC podem englobar desde a simples supervisão de variáveis, verificando se os valores estão dentro de um limite pré-estabelecido, até a detecção de uma anomalia no processo. Técnicas de monitoramento e controle mais sofisticados podem ainda realizar a identificação do componente responsável pela irregularidade observada. Em último caso, o sistema pode ainda gerar um sinal que irá substituir o emitido pelo sensor ou atuador falho, de modo que o processo possa continuar em funcionamento até a próxima manutenção.

Os procedimentos mais utilizados para Detecção e Isolamento de Falhas (DIF) em sistemas complexos se baseiam geralmente na análise da redundância da informação obtida. Esta redundância pode ser classificada em três tipos: física, analítica ou heurística.

Na redundância física, também denominada redundância por *hardware*, dois ou mais sensores realizam a mesma medida em sistemas de monitoração e diagnósticos tradicionais. Nesta classe de redundância, uma votação lógica pode então ser empregada para identificar um componente falho. Apesar de ser um método confiável, fácil de ser implementado e ágil para detectar falhas difíceis, a redundância física possui algumas desvantagens como o custo elevado de instalação e manutenção de uma maior quantidade de sensores, a dificuldade do método em detectar falhas "leves", como um desvio de comportamento de um componente, e a não aplicabilidade em sistemas com alta redundância paralela.

Na redundância analítica, comumente chamada redundância por *software*, a estimativa dos sinais gerados a partir do modelo matemático do sistema monitorado são comparadas com as medidas dos sensores. A principal vantagem deste tipo de

redundância é que não é necessário alterar a infraestrutura de instrumentação existente e de acrescentar novos componentes ao sistema em operação para implementar o algoritmo de monitoramento e detecção de falhas. Porém, o modelamento matemático do processo constitui o grande desafio deste método.

A redundância heurística, também conhecida como redundância de modelos baseados no conhecimento, se apresenta como alternativa, ou complemento, para a redundância analítica e se baseia nos conhecimentos sobre o sistema não reprodutíveis matematicamente, ou apenas parcialmente retratáveis, que são modelados geralmente através de técnicas de Inteligência Artificial.

3 Definição do Problema

O sistema desenvolvido neste estudo visa realizar um diagnóstico preditivo para leitoras de cartões magnéticos sensorizadas encontradas em máquinas de autoatendimento bancário. Os caixas eletrônicos são basicamente sistemas embarcados compostos por módulos independentes, incluindo: computador/processador, leitora de cartões, teclado, monitor, teclas de função, dispensador de dinheiro, leitor de código de barras, impressora de recibos, e dispositivos de segurança (biometria).

A leitora de cartão, objeto de estudo deste trabalho, é um dispositivo para leitura das informações codificadas da tarja magnética do cartão e identificação de um número de conta específico do usuário. Esse módulo captura as informações da conta do cartão e as envia para o processador *host*. A leitora de cartões está sujeita a interferências de fatores externos como a qualidade da tarja magnética e do sistema de posicionamento, entre outros. Falhas de leitura podem ser causadas por tarjas magnéticas desgastadas ou por problemas no conjunto de posicionamento do cartão, que é suscetível à obstrução do seu curso pela falta de lubrificação do trilho-cursor ou por atos de vandalismo como a introdução de objetos.

Embora haja atualmente cartões com *chip* que codificam as informações do cliente necessárias a sua identificação, muitas operadoras de crédito ainda trabalham somente com a tarja magnética ou de forma complementar às informações do *chip*, por isso, o escopo deste trabalho encontra-se atual e totalmente aplicável em leitoras de ATMs ou leitoras de cartões individuais que possuem as mesmas características operacionais.

3.1 Coleta, processamento e análise dos dados utilizados

Segundo Aguiar et al (2006), o processo de diagnóstico, que consiste na identificação dos defeitos a partir dos dados observados, pode ser dividido em três etapas: aquisição, tratamento e análise dos dados. A etapa de coleta engloba a obtenção do histórico de

observações geradas em um intervalo de tempo. O processamento consiste na etapa de transformações matemáticas necessárias para a correta interpretação dos dados pelo método escolhido. Ambas as etapas empregadas neste estudo serão detalhadas na seção 4.

Aguiar et al (2006) afirma que a aquisição e o processamento dos dados podem ser realizados através do auxílio por sensores. Neste tipo de processo diagnóstico, as etapas definidas têm sua execução auxiliada por uma rede de sensores presentes nos componentes que realizam as observações e, dependendo da inteligência do sistema, o processamento dos sintomas. Esta abordagem tem a vantagem de propiciar um pré tratamento dos dados, permitindo, quando do momento da manutenção, que um grande volume de processamento já tenha sido realizado. Na fase atual do sistema proposto, a coleta das ocorrências de falhas é realizada via auxílio por sensores, porém o tratamento, ou processamento, dos dados é efetuado posteriormente fora do ambiente da ATM.

Um sistema é dito diagnosticável para um dado padrão de falha se esse pode ser localizado dentro de uma síndrome. Segundo Aguiar et al (2006), síndrome pode ser definida como o conjunto de características (sintomas) apresentadas pelo equipamento que indicam a situação real de cada componente, ou módulo, naquela circunstância. Dado um sistema diagnosticável e dado uma síndrome por ele produzida, o problema do diagnóstico de falhas é determinar qual padrão de falhas está presente (Vinnakota e Jha, 1993).

O comportamento das falhas pode ser analisado através da função densidade de probabilidade, do histograma da frequência de falhas, da função de probabilidade de falha (ou probabilidade acumulada), da função de probabilidade de sobrevivência (ou confiabilidade), da taxa de falhas (curva da banheira), da disponibilidade e da análise paramétrica (Bertsche, 2009; Slack, Chambers & Johnston, 2015). Neste trabalho, o padrão de falhas foi analisado a partir da taxa de falhas, da análise paramétrica usando a distribuição de Weibull e da disponibilidade.

3.1.1 Taxa de falhas

A taxa de falhas (TF) define a quantidade de falhas que um componente ou sistema apresenta dentro de um determinado intervalo de tempo (Johnson, 1989).

$$\lambda(t) = \frac{\text{Quantidade de Falhas}}{\text{Tempo de Operação}} \quad (1)$$

A maioria das partes físicas de um equipamento eletroeletrônico comporta-se de modo semelhante, sendo caracterizada pela Curva da Banheira (*Bathub Curve*), que descreve a probabilidade de falha desse tipo de componente. A taxa de falhas varia em função do tempo e o ciclo de vida de equipamentos eletroeletrônicos apresenta três períodos muito

característicos: “Mortalidade Infantil”, “Vida Normal” e Desgaste (Slack, Chambers e Johnston, 2015). A fase da “Mortalidade Infantil” é a primeira parte da curva, que ocorre no início da operação do equipamento e caracteriza-se por uma elevada taxa de falhas prematuras, decorrentes de falhas no projeto, falhas de fabricação, defeitos de instalação, componentes defeituosos ou ausentes, e uso inadequado, que decresce com o tempo. Esse fenômeno é também observado em sistemas reparáveis onde os componentes passaram por ações de manutenção. No período intermediário da “Vida Normal”, a taxa de falhas é geralmente baixa (menor do que nas fases de “Mortalidade Infantil” e Desgaste) e aproximadamente constante. As falhas nesse período são causadas por fatores aleatórios e menos comumente devido a defeitos do componente em si. Na etapa de Desgaste, a taxa de falhas aumenta consideravelmente em função do tempo à medida que as peças se aproximam do final de sua vida útil. Nessa fase, as falhas nos componentes são causadas pelo envelhecimento e deterioração (desgaste) das peças decorrentes do uso e da fadiga do material (Slack, Chambers & Johnston, 2015).

3.1.2 Distribuição de Weibull

A análise de confiabilidade de sistemas com características de degradação é comumente realizada através da distribuição de Weibull. A função de taxa de falha é monótona, ou seja, ela é estritamente crescente, constante ou estritamente decrescente (Kales, 1998). A função de probabilidade acumulada de Weibull é calculada conforme equação (2):

$$F(t, \eta, \beta, t_0) = 1 - \exp \left[- \left(\frac{t - t_0}{\eta} \right)^\beta \right] \quad (2)$$

O parâmetro η é a constante de escala, que define o espalhamento da distribuição no eixo x , enquanto β é a constante de forma, que revela o tipo de falha investigado. Ambos η e β assumem valores reais positivos.

Ao se relacionar a distribuição de Weibull com a Curva da Banheira, pode-se deduzir que a função de taxa de falhas é estritamente decrescente na fase de “Mortalidade Infantil”, constante na etapa de “Vida Normal” e estritamente crescente no estágio de Desgaste.

Supondo a taxa de falhas descrita pela função $\lambda(t)$ como uma simplificação da função da probabilidade acumulada de Weibull, a equação (3) representa um processo de Poisson para equipamentos eletroeletrônicos:

$$\lambda(t) = \beta \cdot \mu^\beta \cdot t^\beta \quad (3)$$

O parâmetro β é a constante de forma, μ a constante de escala e t o tempo do sistema. As curvas de Weibull mostram a variação da forma de $\lambda(t)$ com a variação de β , mantendo-se o parâmetro de escala $\mu=0.01$. Pode-se notar que a função de taxa de falhas é decrescente para valores de $\beta < 1$, implicando em

falhas prematuras, constante para $\beta=1$ devido a falhas aleatórias e decrescente para valores de $\beta > 1$ caracterizando o comportamento de desgaste.

Equipamentos que apresentam valores de $\beta > 1$, como, por exemplo, leitores de cartão magnético de ATMs, devido ao desgaste da cabeça de leitura magnética, tendem a apresentar um aumento em sua taxa de falhas. Assim, no plano de manutenção de equipamentos eletroeletrônicos, a detecção de falhas pode ser definida com base em um limiar de decisão denominado nível de qualidade aceitável (NQA, *Acceptance Quality Level*) que sinaliza a necessidade de uma intervenção de manutenção.

3.1.3 Disponibilidade

Outra medida importante em sistemas de diagnóstico de falhas é a disponibilidade, que representa a razão de tempo em que o sistema permaneceu funcionando em relação ao tempo total de operação. A disponibilidade pode ser calculada a partir do tempo médio entre falhas (TMEF ou MTBF, do inglês *Mean Time Between Failures*) e do tempo médio de reparo (TMDR ou MTTR, do inglês *Mean Time To Repair*).

$$\text{Disponibilidade} = \frac{MTBF}{MTBF + MTTR} \quad (4)$$

É importante observar que exercem impacto sobre a disponibilidade os tempos de manutenção corretiva ou preventiva do sistema. A detecção e o diagnóstico rápidos das falhas pode reduzir significativamente o tempo médio de reparo do equipamento, aumentando assim sua disponibilidade.

4 Solução Proposta

A finalidade da solução desenvolvida, baseada em uma pesquisa aplicada, foi fornecer aos técnicos sugestões para estratégia de manutenção e aos engenheiros uma metodologia para o desenvolvimento de algoritmos de controle para a leitora de cartões magnéticos. Em relação aos objetivos, a pesquisa foi descritiva, isto é, procurou-se definir o problema, descrever os elementos e suas relações, investigar e aplicar técnicas para solução do problema e produzir uma sistemática e aplicá-la a um estudo de caso real. O método de investigação adotada neste trabalho foi o dedutivo.

Como mencionado anteriormente, para a análise do desempenho da metodologia aqui proposta, foram selecionadas duas bases de dados ψ_1 e ψ_2 contendo os cem últimos eventos de falha de uma amostra de 1000 leitoras de cartões magnéticos com, respectivamente, comportamento normal e degradado.

O comportamento de cada leitora de cartões magnéticos é representado na forma de um vetor de dimensão 100 denominado X_n , equivalente ao número de falhas coletadas para cada componente. Os valores de cada célula do vetor indicam a posição do evento

de falha, sendo, portanto, estritamente crescente, conforme descrito na distribuição de Weibull e na curva da banheira para sistemas sujeitos à degradação de suas partes físicas e de suas funcionalidades.

4.1 Convolução temporal dos dados de entrada

A coleta de dados do sistema em análise ocorreu sobre uma amostra controlada a fim de prevenir a contaminação dos mesmos com informações imprecisas ou incorretas e possibilitar um maior nível de rastreabilidade dos dados. Os arquivos de registros (*logs*) históricos de sensores indicam situações estáticas dos eventos de falha e não mostram claramente a continuidade temporal entre os padrões sucessivos.

Segundo Peláez (2001), a contribuição de eventos passados e futuros pode ser obtida por meio de uma suavização (*smoothing*) probabilística sobre o tempo para cada evento registrado. Como a maioria dos filtros de *smoothing* são baseados na técnica de convolução, atuando como um filtro passa-baixas (*low-pass frequency filter*), aplicou-se a convolução sobre os dados do vetor de entrada X_n com uma função de distribuição Gaussiana, obtendo-se um vetor $Y_{n,m}$.

A convolução permite a visualização de uma continuidade temporal entre os padrões de falhas sucessivos nos arquivos de *log* em vez de padrões independentes para cada linha. A contiguidade das linhas dos arquivos de *log* implica em semelhança e, desse modo, vetores semelhantes estão localizados próximos no espaço n -dimensional.

4.2 Rede SOFM

Neste estudo, empregou-se o mapa de características auto-organizáveis (SOFM), pois este tipo de rede neural artificial (*Artificial Neural Network*, ANN) categoriza os modos de falha baseado no critério de distância, sem a necessidade de qualquer tipo de suposição prévia ou implícita sobre os dados fornecidos (Peláez et al, 2001).

A rede SOFM, também denominada mapa auto-organizável (SOM) ou ainda mapa, rede ou modelo de Kohonen, é um tipo de ANN com abstração computacional baseada na organização topológica de modelos biológicos de sistemas neurais. Uma das principais características do cérebro humano, o mapeamento topológico significa que os vetores de entrada que estão próximos um do outro no espaço de entrada produzirão vetores próximos um do outro no espaço de saída de duas dimensões (Kohonen, 1982).

Desenvolvida pelo professor finlandês Teuvo Kohonen na década de 1980, a SOFM é treinada usando aprendizado competitivo não supervisionado, diferente da aprendizagem de correção de erros (como *backpropagation* ou gradiente da superfície) da maioria das outras ANNs, a partir do espaço de entrada das amostras de treinamento, denominado mapa, que reduz consideravelmente a

dimensionalidade dos padrões de entrada e, por conseguinte dos padrões de saída.

Por essas características, a SOFM tem sido utilizada para agrupamento (ou clusterização) de dados, redução de dimensionalidade, predição estruturada, e detecção de anomalias em diversos domínios como meteorologia, oceanografia, exploração de petróleo e gás, gerenciamento de projetos e engenharia de confiabilidade (Kohonen, 1982).

Neste trabalho, a aplicação da rede SOFM, contendo uma camada intermediária e dois neurônios na camada de saída, foi realizada após o processo de convolução dos dados buscando reduzir a dinâmica espaço-temporal de um espaço de entrada complexo em uma dinâmica com número limitado de neurônios através da conversão de sequências complexas de dados de entrada em uma classificação simples de neurônios vencedores em uma camada de saída bidimensional.

Para o treinamento da SOFM, as duas bases ψ_1 e ψ_2 foram agrupadas em uma base de dados única ψ_{in} resultando em uma matriz de 100 colunas por 2000 linhas. Este conjunto de dados ψ_{in} foi então dividida em três subconjuntos: um contendo os dados para treinamento da rede ψ_{tr} com cerca de 80% dos equipamentos, aproximadamente 20% dos dados de treinamento foram utilizados para teste ψ_{tt} , e um último conjunto de dados inéditos (20%), escolhidos aleatoriamente na base inicial, para validação da rede ψ_{vd} . Como etapa final, tem-se o conjunto dos vetores de saída (*target*) Φ , com dimensão 1×1600 .

Para o desenvolvimento desse algoritmo, assumiu-se que as falhas são binárias, ou seja, apresentam somente dois estados possíveis: zero (0) ou um (1). Dessa forma, para cada vetor de entrada da base ψ_1 é associado ao valor 1 na correspondente componente de Φ , enquanto para os vetores de ψ_2 , o valor associado em Φ é zero, seguindo a organização topológica mencionada anteriormente.

Para o processamento dos dados, criação e treinamento da rede SOFM foi utilizado o software Matlab®, versão R2015a. A rede foi criada com duas camadas de neurônios, 1000 iterações totais para treinamento (épocas), topologia hexagonal e função de distância de Manhattan entre neurônios.

4.3 Resultados Obtidos

As taxas de falhas obtidas para os sistemas com comportamento normal e degradado estão ilustradas na Tabela 1.

Tabela 1. Taxa de Falhas em Partes Por Milhão (PPM).

	Sistema Normal	Sistema Degradado
Taxa de falhas	1,2547 PPM	139,91 PPM

A Tabela 1 mostra claramente que a taxa de falhas no módulo leitora de cartões magnéticos operando em

condição normal (fase “Vida Adulta da Curva da Banheira”) é muito inferior à taxa de falhas do componente degradado (fase “Desgaste”).

A Figura 1 apresenta os eventos de falha na leitora de cartões magnéticos da ATM em análise.




Figura 1. Amostra, contendo os 100 registros temporais (eixo vertical) para 100 equipamentos, da evolução de eventos de falhas no módulo leitora de cartão magnético de ATM. Em (a) pode-se avaliar os 100 últimos registros de falhas de 100 leitoras que estão operando em modo normal. Em (b) está a amostra de 100 leitoras operando em modo degradado.

É claramente observável a evolução da taxa de falhas neste tipo de equipamento que apresenta poucos eventos no início da sua vida útil com crescente acúmulo com a evolução do tempo (eixo vertical da Figura 1b), culminando em uma sequência de erros operacionais que inviabilizam ou impossibilitam sua utilização. Na Figura 1a, embora uma primeira avaliação rápida possa sugerir uma ocorrência maior de falhas comparativamente à Figura 1b, pode-se notar que há uma distribuição regular das falhas, característica do modo normal de utilização do equipamento. Deve-se também lembrar que os registros aqui utilizados referem-se às últimas 100 ocorrências de falhas para cada tipo de operação sendo que em modo normal o intervalo de operação considerado é aproximadamente 100 vezes maior.

A distribuição de Weibull aplicada aos dados dos arquivos de registros (*log*) históricos de sensores corrobora com o comportamento observado na Tabela 1 (taxa de falhas) à medida que revela uma função de taxa de falhas razoavelmente constante na etapa de “Vida Normal” e estritamente crescente no estágio de “Desgaste”.

Com a finalidade de encontrar a melhor saída da Rede SOFM a partir dos dados de treinamento, teste e validação, de modo a garantir o poder de generalização da arquitetura proposta, foram realizadas algumas simulações com variação do

parâmetro desvio-padrão da função de convolução aplicada aos dados de entrada.

Assim, foram utilizados três valores de desvio-padrão: 1, 2 e 3, obtendo-se os resultados de classificação da Rede SOFM conforme a Figura 2 que apresenta os resultados para o treinamento desta topologia.




Figura 2. Resultado do treinamento da SOFM com variação do parâmetro de desvio-padrão da função de convolução. Em (a) encontra-se o resultado do treinamento com desvio-padrão da função de convolução igual a 1, em (b) este mesmo parâmetro é igual a 2 e, em (c) encontra-se o resultado para o valor 3 de desvio-padrão. Os dados no canto inferior esquerdo referem-se ao modo degradado de operação.

Podemos observar que, independentemente do valor do desvio-padrão utilizado na função de convolução na fase de tratamento dos dados, a rede SOFM é capaz de distinguir claramente o centro de área de cada agrupamento, normal ou falho.

Para a fase de validação dos resultados, foi escolhido o valor de desvio-padrão igual a 3 por apresentar uma maior correlação dos dados de entrada. Os resultados de classificação da rede SOFM empregada podem ser vistos na Figura 3.




Figura 3. Resultado da validação da SOFM com valor de desvio-padrão da função de convolução igual a 3. Em (a) encontram-se os dados do estado degradado e, em (b) estão os dados inéditos utilizados para validação do modelo. Em ambos os casos houve 100% de acerto na classificação dos dados pela SOFM.

Estes resultados demonstram que, utilizando-se a arquitetura da solução aqui proposta que inclui o tratamento dos dados de entrada utilizando convolução gaussiana e a rede SOFM na fase de análise dos dados, é possível classificar os padrões de entrada de equipamentos de leitora de cartão magnético com 100% de acerto, independentemente do valor do desvio-padrão utilizado na fase de tratamento. Assim, com esta metodologia e com os dados disponíveis neste estudo, não houve ocorrência de Falso Alarme ou Perda de Diagnóstico.

4 Conclusão

A avaliação de desempenho da arquitetura SOFM revelou resultados muito satisfatórios para o diagnóstico de falhas em equipamentos com sintomas de degradação, como no caso do módulo leitora de cartões magnéticos do ATM analisado.

Esses resultados demonstram que o objetivo deste estudo (determinar a viabilidade da utilização da arquitetura proposta que utiliza a SOFM para o diagnóstico de falhas em sensores de uma leitora de cartões magnéticos de uma ATM) foi atingido e que a metodologia empregada é promissora para a detecção e o diagnóstico de falhas a ser implementada nos caixas eletrônicos em escala comercial.

Comparando-se o desempenho da rede SOFM empregada neste estudo com a sistemática baseada na arquitetura MLP em Destro, Aguiar e Furucho (2010), pôde-se observar que a SOFM obteve um desempenho extremamente melhor que a MLP na predição de estados futuros de degradação para este tipo de módulo.

O diagnóstico de falhas é um problema complexo. Estudos demonstram que uma abordagem de manutenção usando técnicas de Inteligência Artificial contribui consideravelmente para o aumento de confiabilidade e disponibilidade dos sistemas monitorados, para a redução dos custos operacionais e de manutenção e para a otimização das políticas de manutenção das empresas do setor de automação bancária.

Com base nisso, os próximos passos deste estudo serão a comparação destes resultados com outras técnicas de análise de dados, bem como a utilização de janelamento com aplicação de média móvel e limiar de decisão e de outros processos de pré-tratamento dos dados, e também a aplicação destas abordagens em outros módulos dos caixas eletrônicos.

Agradecimentos

Agradecimentos especiais ao Departamento Acadêmico de Eletrotécnica da UTFPR, à Diretoria de Elétrica do IFSP e ao Departamento de Engenharia Elétrica da FEI.

Referências Bibliográficas

- ABNT (1994), *NBR 5462: Confiabilidade e manutenibilidade*. Rio de Janeiro: 1994.
- Aguiar, M.A., Inojosa Filho, R., Furucho, R.A. and Kovacs, Z.L. (2006), Detecção e Diagnóstico Preditivos de Falhas em Equipamentos de Automação Bancária Utilizando Redes de Sensores. *5º Congresso Iberoamericano de Sensores - IBERSENSOR 2006*, 2006, Montevideo. Anais do 5º Congresso Iberoamericano de Sensores, 2006. v. 5.
- Bertsche, B. (2009), *Reliability in automotive and mechanical engineering*. Stuttgart: Springer, 2009.
- Goble, W. M. (1998), *Control Systems Safety Evaluation & Reliability*. ISA: the instrumentation, systems and automation society, 2 ed., 1998.
- Hines, J.W., Miller, D.W. and Hajek, B.K. (1996), A hybrid approach for detecting and isolating faults in nuclear power plant interacting systems. *Nuclear technology*, 115(3), pp.342-358.
- IEC (2003), *International Eletrotechnical Commission. Functional safety: Safety instrumented systems for the process industry sector (IEC 61511)*, International Eletrotechnical Commission, Geneva, Switzerland, 2003.
- Kales, P. (1998), *Reliability for technology, Engineering, and Management*. Prentice Hall, 1998.
- Kohonen, T. (1982). Self-organized formation of topologically correct feature maps. *Biological cybernetics*, 43(1), pp.59-69.
- Leonard, J.A. and Kramer, M.A. (1993), Diagnosing dynamic faults using modular neural nets. *IEEE Expert*, 8(2), pp.44-53.
- Pelaez, J.R., Aguiar, M.A., Destro, R.C., Kovács, Z.L. and Simões, M.G. (2001). Predictive maintenance oriented neural network system-PREMON. *Industrial Electronics Society, 2001. IECON'01. The 27th Annual Conference of the IEEE* (Vol. 1, pp. 49-52). IEEE.
- Silva Filho, R.I., Aguiar, M.A. and Kovács, Z.L. (2005), Um estudo de caso genérico de diagnóstico preditivo para sistemas complexos.
- Slack, N.; Chambers, S. and Johnston, R. (2015) *Administração da produção*. 4ª ed. São Paulo: Atlas, 2015.
- VDI/VDE (1998). *General guide to the VDI-Handbook reliability engineering*. VDI 4001 Blatt 1, The Association of German Engineers (VDI)
- Vinnakota, B. and Jha, N. K. (1993), Diagnosability and Diagnosis of Algorithm-Based Fault-Tolerant Systems. *IEEE Transactions on Computers*, v. 42, n. 8, August 1993