

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E
TECNOLOGIA DE SÃO PAULO

CAMPUS SÃO PAULO

ALESSANDRO LINS ALVES

**SISTEMA DE IDENTIFICAÇÃO DE FALHAS EM ESCADAS
ROLANTES UTILIZANDO REDES NEURAIS ARTIFICIAIS.**

São Paulo

2015

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E
TECNOLOGIA DE SÃO PAULO – IFSP

ALESSANDRO LINS ALVES

**SISTEMA DE IDENTIFICAÇÃO DE FALHAS EM ESCADAS
ROLANTES UTILIZANDO REDES NEURAIS ARTIFICIAIS.**

Dissertação de Mestrado apresentada ao Instituto Federal de Educação, Ciência e Tecnologia de São Paulo – IFSP como parte dos requisitos para obtenção do título de Mestre em Automação e Controle de Processos.

Orientador: Prof. Dr. Alexandre Simião Caporali

Coorientador: Prof. Dr. Paulo Roberto Barbosa

São Paulo

2015

Alves, Alessandro Lins
A474s Sistema de identificação de falhas em escadas rolantes
utilizando redes neurais artificiais / Ed Alencar Dias da Silva.
São Paulo: [s.n.], 2015.
84 f.; il.

Orientador: Prof. Dr. Alexandre Simião Caporali.
Co-Orientador: Prof. Dr. Paulo Roberto Barbosa

Dissertação (Mestrado em Automação e Controle de Processos.)
- Instituto Federal de Educação, Ciência e Tecnologia de São Paulo,
IFSP, 2015.

1. Redes neurais artificiais 2. Mapas auto-organizáveis 3. Escada
rolante 4. Gerenciamento de falhas I. Instituto Federal de
Educação, Ciência e Tecnologia de São Paulo II. Título
CDD 670.427

ATA DE EXAME DE DEFESA DE DISSERTAÇÃO

Nome do Programa: **Mestrado Profissional em Automação e Controle de Processos**

Nome do(a) Aluno(a): Alessandro Lins Alves

Nome do Orientador: Prof. Dr. Alexandre Simião Caporali

Nome do Coorientador: Prof. Dr. Paulo Roberto Barbosa


Título do Trabalho: "Sistema de identificação de falhas em escadas rolantes utilizando redes neurais"

Abaixo o resultado de cada participante da Banca Examinadora

Nome completo dos Participantes Titulares da Banca	Sigla da Instituição	Aprovado / Não Aprovado
Prof. Dr. Alexandre Simião Caporali – Orientador	IFSP – SPO	<i>Aprovado</i>
Prof. Dr. Ênio Carlos Segatto – Membro Interno	IFSP – SPO	<i>APROVADO</i>
Profª Drª Graziela Marchi Tiago - Membro Externo	IFSP - SJC	<i>graziela / aprovado</i>
Nome completo dos Participantes Suplentes da Banca	Sigla da Instituição	Aprovado / Não Aprovado
Prof. Dr. Alexandre Brincalepe Campo – Membro Interno	IFSP – SPO	
Prof. Dr. Eduardo Alves da Costa – Membro Interno	IFSP – SPO	

Considerando-o: ☒ APROVADO
☐ NÃO APROVADO

Assinaturas

São Paulo, 05 de outubro de 2015
Presidente da Banca
Membro Interno
Membro Externo

Observações:

A data final para a entrega da versão último é 05/12/2015

AGRADECIMENTOS

Primeiramente gostaria de agradecer a Deus, pois sem ele eu não teria chegado até aqui.

Ao Prof. Dr. Alexandre Simião Caporali pelo apoio incondicional e orientação precisa. Agora compreendo melhor o papel do orientador, porque sem ele este trabalho não teria rumo.

Faço um agradecimento especial ao Prof. Dr. Paulo Roberto Barbosa, pois sem ele a conclusão deste trabalho seria simplesmente impossível.

A minha família, minha esposa Renata, aos meus filhos Gabriel e Samuel pela compreensão, apoio e paciência durante o tempo que me dediquei a este trabalho.

Aos meus amigos do trabalho Adilson, Fábio, Moisés, Eduardo, Jair e Marcos pela ajuda e pelos ouvidos que suportaram meus infindáveis detalhes sobre cada momento deste projeto.

Aos meus estimados chefes por todo o apoio, permitindo que os dados fossem coletados.

Aos demais colegas que me ajudaram direta ou indiretamente na confecção deste trabalho.

RESUMO

Escadas Rolantes são importantes meios de locomoção dentro de sistemas metro-ferroviários. Em caso de falhas, elas podem parar bruscamente, podendo gerar graves acidentes. Desta forma, é fundamental que a detecção das falhas neste equipamento ocorra de forma correta. O objetivo deste trabalho é diminuir a incidência de paradas desnecessárias nas escadas rolantes, evitando assim graves acidentes, transtornos aos usuários e também diminuindo custos com manutenção. Para isto, foi desenvolvido um dispositivo de baixo custo para captar os dados vibracionais de uma escada rolante. De posse destes dados, foi realizado um estudo de viabilidade da utilização de uma rede neural artificial do tipo mapa auto-organizável, para que estes dados fossem classificados corretamente e com isto o sistema pudesse diferenciar uma falha real de uma falsa falha em uma escada rolante. O modelo proposto obteve 77,67% de acerto na classificação das falhas, em relação a outros tipos de sinais provenientes da vibração das escadas rolantes.

Palavras chave: redes neurais artificiais; mapas auto-organizáveis; escada rolante; gerenciamento de falhas.

ABSTRACT

Escalators are important means of locomotion within metro-rail systems. In case of failure, they can stop abruptly and may cause serious accidents. Thus, it is essential that the detection of faults occurring in this equipment correctly. The objective of this work is to reduce the incidence of unnecessary stops on escalators, thus avoiding serious accidents, inconvenience to users and reducing maintenance costs. For this, a low cost device is designed to raise the vibrational data of an escalator. Using these data, a feasibility study of the use of an artificial neural network, of type self-organizing map, so that these data were classified correctly and that the system could differentiate an actual failure of a false failure on an escalator. The proposed model has obtained 77.67% of correct classification of failures in relation to other types of signals from the vibration of escalators.

Keywords: artificial neural networks; self-organizing maps; escalator; fault management.

LISTA DE FIGURAS

Figura 1.1 – Desenho esquemático de uma escada rolante.....	14
Figura 1.2 – Distribuição das falhas em escadas rolantes no Metrô SP.	17
Figura 1.3 – Média de falhas em escadas rolantes por estação no Metrô SP. .	18
Figura 1.4 – Distribuição das falhas em escadas rolantes – Linha 5 – Lilás.....	19
Figura 2.1- Modelo de escada rolante.	22
Figura 2.2 – Modelo Computacional da Corrente e Coroa de Tração.....	24
Figura 2.3 – Modelo esquemático de Inspeção.	26
Figura 3.1 - Diagrama de Blocos do sistema nervoso.	30
Figura 3.2 – Neurônio natural – Célula piramidal.....	31
Figura 3.3 – Modelo matemático de um neurônio.....	32
Figura 3.4 – Arquitetura de uma PMC com duas camadas ocultas.	35
Figura 3.5 - Modelos de mapas auto-organizáveis de características.	36
Figura 4.1 - Analisador de vibração com indicação de eixos.	44
Figura 4.2 - Parte interna do Analisador de vibração.....	44
Figura 4.3 – Protótipo de analisador de vibração.	45
Figura 4.4 – Analisador instalado em uma ER.....	48
Figura 5.1 – Vibração nos eixos X, Y e Z da ER1.....	49
Figura 5.2 – Vibração nos eixos X, Y e Z da ER2.....	50
Figura 5.3 – Frequência de vibração ER1.	51
Figura 5.4 – Frequência de vibração ER2.	51
Figura 5.5 – Efeito dos passageiros sobre a ER2 nos eixos Y e Z	52
Figura 5.6 – Padrão de vibração ER2 sem usuários.	53
Figura 5.7 – Padrão de vibração ER2 com baixa movimentação de usuários..	54
Figura 5.8 – Padrão de vibração ER2 com alta movimentação de usuários.....	54
Figura 5.9 – Falha ER2.....	55
Figura 5.10 – Falha ER2 – Frequências.	56
Figura 5.11 – Modelos de frequências da ER2 ao longo do dia.....	56
Figura 5.12 - Matriz de distâncias Unificadas - U-matrix.....	59
Figura 5.13 - Distribuição dos neurônios vencedores.....	60
Figura 5.14 - Distribuição dos neurônios vencedores.....	60
Figura 5.15 - Formação dos agrupamentos (clusters) da RNA.....	61

Figura 5.16 - Distribuição dos neurônios vencedores, utilizando os dados de generalização.....	63
---	----

LISTA DE TABELAS

Tabela 1- Parâmetros de Configuração RNA.....	58
Tabela 2- Amostras gerais por região da RNA.....	62
Tabela 3- Taxa de acerto por amostras gerais da RNA.....	64

LISTA DE ABREVIATURAS E SIGLAS

- AM - Alto Movimento de Passageiros
- AMV – Aparelho de Mudança de Via
- BM - Baixo Movimento de Passageiros
- BMU - *Best Matching Unit* - (Unidade de Melhor Casamento)
- CLP – Controlador Lógico Programável
- CITEF – Centro de Investigação em Tecnologias Ferroviárias
- ER – Escada Rolante
- F - Falha
- FFT – *Fast Fourier Transfer* (Transformada Rápida de Fourier)
- Innotrack – *Innovative Track Systems* (Sistemas Inovadores sobre Trilhos)
- NBR – Norma Brasileira Regulamentadora
- PMC – *Perceptron* de Multi Camadas
- RNA – Rede Neural Artificial
- SM - Sem Movimento de Passageiros
- SOM - *Self Organizing Maps* - (Mapas Auto-Organizáveis)
- STME – *Single-Throw Mechanical Equipment* (Equipamentos Mecânicos de Movimentação Única)
- UIC – União Internacional de Ferrovias

Sumário

LISTA DE FIGURAS

LISTA DE TABELAS

LISTA DE ABREVIATURAS E SIGLAS

1.	Introdução.....	14
1.1	Justificativas	16
1.2	Objetivo Geral	19
1.3	Objetivos específicos.....	20
1.4	Organização da dissertação.....	20
2.	Revisão da Literatura.....	22
3.	Teoria de Redes Neurais Artificiais	30
3.1	Introdução	30
3.2	Rede Neural PMC	34
3.3	Rede Neural SOM	35
3.3.1-	Formação do Mapa Auto-Organizável.....	37
3.4-	Resumo do Algoritmo SOM.....	41
4.	Materiais e Métodos	43
4.1	Princípio de Funcionamento.....	46
4.2	Procedimento de aquisição dos dados.....	47
5.	Análise de Dados e Simulações Computacionais.....	49
5.1	Análise de falhas	53
5.2	Utilização de Mapas Auto-organizáveis.....	57
5.3	Análise dos Mapas	59
6.	Conclusões e Sugestões para Trabalhos Futuros	65
6.1-	Sugestões para Trabalhos Futuros	66
7.	Bibliografia	67
APÊNDICE A - Programa do Analisador de Vibrações desenvolvido na		

plataforma Arduino.	70
APÊNDICE B – Algoritmo <i>do</i> Matlab para análise de vibrações no tempo.	76
APÊNDICE C - Algoritmo <i>Script do</i> Matlab para análise de vibrações na frequência.....	78
APÊNDICE D - Algoritmo <i>Script do</i> Matlab para análise e desenvolvimento da RNA SOM.....	80
ANEXO A - Sumário do Datasheet do Microcontrolador ATmega328P da Atmel.....	82
ANEXO B - Sumário do <i>Datasheet</i> do Acelerômetro ADXL345 da Analog Devices.....	84

1. Introdução

Uma das grandes responsáveis pelo correto fluxo de passageiros, dentro de estações metro-ferroviárias são as Escadas Rolantes (ERs). Pode-se ver na figura 1.1 um desenho de uma ER contendo suas principais partes constituintes. Quando uma ER apresenta uma falha ficando fora de operação, são gerados grandes transtornos devido à dificuldade para transpor os diversos níveis arquitetônicos. Esta situação pode levar ao acúmulo de passageiros nos corredores de circulação. Em estações de grande fluxo, esta aglomeração pode inclusive levar a tumultos entre os passageiros.




Figura 1.1 – Desenho esquemático de uma escada rolante.

Fonte: Thyssenkrupp Elevadores, 2007

A definição do conceito de falha, citada anteriormente, de acordo com Pinto (1999) baseada na NBR 5462-1994, é a seguinte:

“A falha é o término da capacidade de um item desempenhar a função requerida. É a diminuição total ou parcial da capacidade de uma peça, componente ou máquina de desempenhar a sua função durante um período de tempo, quando o item deverá ser reparado ou substituído. A falha leva o item a um estado de indisponibilidade. ”

Por estes motivos as falhas são situações indesejáveis nos equipamentos, pois podem torná-los indisponíveis. Embora a situação de falha seja inerente a qualquer tipo de dispositivo, é necessário mitigá-las, quando possível, ou ao menos diminuir seus efeitos.

1.1 Justificativas

No momento da falha, a parada repentina da ER pode causar o desequilíbrio das pessoas causando diversas lesões tais como: cortes; contusões; aprisionamento de dedos; quedas; escoriações; fraturas; e em certos casos esmagamentos levando até ao sufocamento (Al-SHARIF *et al.*, 2012). Para evitar estes acidentes, as ERs possuem diversos sensores e atuadores ao longo de seu corpo, tanto para preservar seu funcionamento, como para manter a segurança dos usuários. Por exemplo, existe um sensor que detecta se um corpo estranho está preso em um degrau (sensor de rodapé), em caso positivo, esta informação é enviada ao CLP de controle da ER e um comando de parada é enviado imediatamente.

Por outro lado, por ser um equipamento que possui várias partes móveis, como por exemplo, motor, corrimãos, degraus, é natural que durante seu funcionamento ela apresente diversas vibrações provenientes destas partes. Além destas vibrações que são naturais do equipamento, quando o fluxo de passageiros é muito alto, podem também ocorrer outras vibrações decorrentes da movimentação destes passageiros sobre a ER. A somatória destas vibrações pode levar os sensores a diagnosticar de forma equivocada uma falha. Ou seja, esta detecção indevida provoca a atuação de dispositivos de proteção, que atuam sem necessidade, levando as ERs a pararem em momentos inesperados. Assim temos o que chamamos de falsas falhas. Por exemplo, a vibração causada pela passagem apressada dos usuários, pode gerar uma vibração, que dispara indevidamente o sensor que monitora o cedimento do degrau, desta forma, é enviado um comando ao CLP que comanda a ER, para que ela pare imediatamente.

A ER não diferencia uma falha real de uma falsa falha, em ambos os casos ela para. Como mencionado anteriormente, as falhas podem ocasionar graves acidentes com os passageiros, além de acarretar grandes custos materiais (deslocamento das equipes de manutenção corretiva sem necessidade) e também imateriais (descontentamento dos usuários devido à indisponibilidade do equipamento).

Em levantamentos preliminares, verificou-se que no parque instalado de escadas rolantes da Companhia do Metropolitano de São Paulo - Metrô SP, cerca de 2/3 das falhas ocorridas nas ERs são finalizadas sem que se saiba o real motivo que

levou a parada do equipamento.

Na figura 1.2 é apresentado um gráfico com a distribuição do total de falhas ocorridas, no período de um ano, nas escadas rolantes das quatro linhas que pertencem e são administradas pelo Metrô SP. Que são: Linha 1 Azul – L1 que liga as estações Jabaquara à Tucuruvi, totalizando 23 estações. Linha 2 Verde – L2, que liga as estações Vila Prudente à Vila Madalena, totalizando 14 estações. Linha 3 Vermelha – L3, que liga as estações Barra Funda a Corinthians Itaquera, totalizando 18 estações. Linha 5 Lilás – L5, que liga as estações Capão Redondo à Adolfo Pinheiro, totalizando 7 estações. Porém, neste trabalho, não foram analisados os dados da estação Adolfo Pinheiro, por ter sido inaugurada após o período estudado. As cores apresentadas representam as respectivas linhas. É importante ressaltar que as tecnologias empregadas nas ERs diferem em cada linha do Metro SP, dependendo do fabricante, do modelo e do momento histórico em que foram implantadas. Nas L1 e L3 estão instalados os equipamentos mais antigos, dos fabricantes Otis e Villares e que dispõem de menos sensoramento eletrônico. A L2 possui ERs dos mesmos fabricantes anteriormente citados além de equipamentos mais modernos e com mais sensores e recursos de segurança do fabricante *Thyssenkrupp*. Já na L5 todas as ERs são do fabricante *Thyssenkrupp*.




Figura 1.2 – Distribuição das falhas em escadas rolantes no Metrô SP.

Conforme dito anteriormente, as ERs mais modernas possuem mais componentes eletrônicos, sensores e atuadores distribuídos em seu corpo, todos eles

compõem o conjunto de itens de segurança da ER. Apesar destes itens serem muito importantes, tanto para a segurança operacional do equipamento, quanto para a integridade física dos usuários, sua atuação indevida pode levar a ER a parar inesperadamente, pois toda atuação de um item de segurança leva imediatamente a parada do equipamento.

Pelos procedimentos de segurança do Metrô SP estas atuações são consideradas, e tratadas inicialmente, como sendo uma falha.

Para exemplificar a diferença da quantidade de falhas apresentadas pelos equipamentos mais antigos e os mais modernos, na figura 1.3 é mostrado um gráfico contendo a quantidade total de falhas no período analisado dividido pela quantidade total de estações que compõem cada linha do Metrô de SP. Assim pode-se observar que embora a L5 possua a menor quantidade total de estações, apresenta a maior média de falhas de ER comparando-se com as outras linhas.




Figura 1.3 – Média de falhas em escadas rolantes por estação no Metrô SP.

A figura 1.4 mostra um gráfico com os diagnósticos de encerramento das falhas das ERs pertencentes a L5 do Metro SP. Estes diagnósticos são feitos pelos técnicos de manutenção corretiva, após a resolução de uma falha. Pode-se observar que do total de falhas, 20% são consideradas falhas reais, ou seja, aquelas em que algum componente efetivamente foi avariado e que 68% das falhas são finalizadas sem que se descubra o real motivo que levou o equipamento a parar. Ou seja, são

provavelmente falsas falhas.




Figura 1.4 – Distribuição das falhas em escadas rolantes – Linha 5 – Lilás.

1.2 Objetivo Geral

O principal objetivo deste trabalho é classificar corretamente os diversos sinais vibracionais da ER, diferenciando-os entre padrões normais e padrões de falha. Desta forma, saber se o equipamento está ou não em falha. E assim, diminuir consideravelmente o número de ocorrências com causas não identificadas nas ERs. Ou seja, pretende-se diminuir a incidência de falsos indicativos de falha em, ao menos, 20%.

Para alcançar este objetivo, foi desenvolvido neste trabalho, um equipamento de baixo custo para coletar os dados vibracionais da ER, montando padrões de vibração ou assinaturas de funcionamento. Esses dados foram utilizados em uma rede neural do tipo SOM - *Self Organizing Map* - (Mapa Auto-Organizável) que realizou a separação e classificação destes sinais em normais e de falha.

1.3 Objetivos específicos

- Desenvolver um dispositivo para captar e armazenar as vibrações provenientes de uma ER.
- Desenvolver e testar um algoritmo para analisar estas vibrações.
- Verificar a influência da movimentação dos usuários sobre a ER.
- Estudar a viabilidade do uso de técnicas de inteligência artificial na indústria metro-ferroviária.
- Desenvolver uma RNA do tipo SOM e testar a eficácia desta rede para separação e classificação dos dados obtidos.

1.4 Organização da dissertação

A fim de alcançar os objetivos anteriormente descritos, propõe-se a seguinte divisão na elaboração desta dissertação:

Capítulo 1 – Introdução;

Capítulo 2 – Revisão da literatura – Na revisão da literatura são apresentados trabalhos referentes às técnicas de modelagem e predição de falha aplicadas às ERs e também na indústria metro-ferroviária;

Capítulo 3 – Teoria sobre Redes Neurais Artificiais – São apresentadas as fundamentações teóricas sobre a utilização de redes neurais relacionadas à classificação de sistemas;

Capítulo 4 – Materiais e Métodos – São apresentados os materiais e os métodos utilizados para a obtenção dos dados a serem utilizados pelo sistema proposto;

Capítulo 5 – Análise de Dados e Simulações Computacionais – São apresentados os resultados e as simulações computacionais obtidos relativos ao desempenho do sistema proposto;

Capítulo 6 – Conclusões e Sugestões para Trabalhos Futuros – São apresentadas as conclusões deste estudo, bem como são feitas algumas sugestões sobre o desenvolvimento de trabalhos futuros.

2. Revisão da Literatura

Existem poucos trabalhos científicos que abordam as ERs (CANO-MORENO *et al.*, 2012). Desta forma, apresentam-se a seguir, através de uma revisão analítica, os diversos desenvolvimentos relativos à modelagem, análise e predição de falhas em escadas rolantes. O principal objetivo é analisar a literatura científica produzida sobre o assunto.

As modernas escadas rolantes são derivadas de invenções com mais de 150 anos de idade, a primeira patente deste equipamento é de 1859, e foi requerida por Natham Ames. Na figura 2.1 pode-se ver seus esboços. Desde então se mantém sua concepção mecânica básica (CABANELLAS *et al.*, 2008). Logo em seus primeiros anos foram patenteados diferentes sistemas visando itens de segurança. Como por exemplo, freios, parada de emergência e controle de velocidade. Alguns destes sistemas estão descritos em John (1913); Woodward (1925); Radcliffe (1926); Blackburne (1926). Ou seja, desde sua invenção até os dias atuais, foram desenvolvidos e patenteados sistemas que visam melhorar a segurança e o conforto dos usuários além de minimizar os custos com energia, ou que tratem especificamente sobre métodos de análise ou redução de falhas nestes sistemas.




Figura 2.1- Modelo de escada rolante.

Fonte: Ames, 1859

ERs são sistemas multi-corpos e por esta característica de difícil modelagem computacional. Os pesquisadores do CITEF (Centro de Investigación en Tecnologías Ferroviárias) ligado à Universidade Politécnica de Madri Espanha, desenvolveram um complexo sistema dinâmico para modelar as interações mecânicas dos diversos componentes de uma ER. Utilizando *softwares* como MATLAB, da empresa Mathworks, CATIA e SIMPACK da empresa Dassault *Systèmes*. O objetivo deste trabalho foi minimizar os custos com desenvolvimento e testes cinemáticos nas ERs. Primeiramente foram simuladas as interações mecânicas dos elos da corrente principal de tração com a coroa de tração e os degraus (CABANELLAS *et al.*, 2008).

Este sistema foi sendo aperfeiçoado utilizando técnicas de *design* robusto para aperfeiçoar alguns parâmetros de desenvolvimento das ERs, tais como: amortecimento; rigidez e forças pré-carga. O sistema simula a velocidade de deslocamento da ER com e sem passageiros e verifica os esforços e os tempos de respostas envolvidos. Os autores informam que este modelo possui mais de 1000 graus de liberdade e que foi testado simulando diversos comportamentos das ERs (CANO-MORENO *et al.*, 2009).

Kwon (1998) pesquisador da Universidade Nacional de Pusan na Coréia do Sul, desenvolveu um modelo dinâmico parcial de uma ER simulando seus degraus, dando ênfase a três aspectos: consumo de energia; vibração; e forças reativas nos rolamentos do mesmo. No ano de 2005, o mesmo autor, juntamente com Park, (da Universidade Nacional de Pusan, Coréia do Sul) e Copeland, (do centro de pesquisas da empresa Otis-LG elevadores) desenvolveram outro estudo, simulando as dinâmicas envolvidas com o corrimão da ER. Segundo os autores, este componente é totalmente não linear e o modelo desenvolvido tem centenas de graus de liberdade. Neste trabalho, é descrito que tradicionalmente as ERs são projetadas e testadas de forma empírica e que estes métodos não conseguem verificar todas as características dinâmicas do equipamento. O modelo apresentado foi testado e apresenta um erro menor que 10% em relação aos dados experimentais, os autores acreditam que este modelo pode ajudar a diminuir o consumo de energia em diferentes configurações de operação.

Isaac Kwon (2012) apresentou ao MIT (Massachusetts Institute of Technology), um estudo de caso de modificação de uma ferramenta (*toolkit*) do *software* RecurDyn,

da empresa *Function Bay*, para modelar parte de uma escada rolante (corrente e coroa de tração). Ele apresenta um cenário atual sobre os *softwares* comumente utilizados para modelagem dinâmica, cita a grande dificuldade em se simular dinamicamente escadas rolantes devido ao grande número de graus de liberdade envolvidos neste sistema e que nenhum destes softwares consegue modelar corretamente a complexidade das ERs. Segundo o autor, até 2010 nenhum *software* entre os líderes de mercado, apresentava alguma ferramenta que auxiliasse no desenvolvimento de modelos de ERs. Desta forma, eram utilizados modelos simplificados de ERs que chegavam a demorar três semanas para serem simulados. O RecurDyn contém alguns modelos chamados de *toolkits* que auxiliam no desenvolvimento de modelos dinâmicos, os *toolkits* podem ser alterados pelos usuários avançados possibilitando novos usos dos modelos. Em seu trabalho, o autor modificou um *toolkit* chamado *chain* para simular a corrente de tração e o coroa de uma ER, como visto na figura 2.2, o autor afirma que este modelo tem grande fidelidade e pode ser gerado em apenas algumas horas. Ele concluiu que as modificações e inovações gerados pelos usuários avançados levaram o software RecurDyn a ganhar mercado rapidamente, levando-o a dominar a indústria de escadas rolantes e elevadores em um curto período de tempo.




Figura 2.2 – Modelo Computacional da Corrente e Coroa de Tração.

Segundo Pinto (1999) são definidos basicamente três tipos de atuação em relação à manutenção: **corretiva**; quando o reparo ocorre após a avaria; **preventiva**; atuações periódicas no equipamento a fim de evitar possíveis falhas; e **preditiva**; atuações nos equipamentos somente quando ocorrem mudanças no seu desempenho. Tradicionalmente são utilizadas técnicas de manutenção corretiva e preventiva em ERs.

Devido ao grande aumento de passageiros nos sistemas metro-ferroviários mundiais, é cada vez maior a necessidade de confiabilidade de todos os sistemas envolvidos, desta forma estão sendo produzidos diversos estudos para que a manutenção dos equipamentos seja aperfeiçoada (SILMON, 2008).

Como citado anteriormente, existem poucos artigos que tratam especificamente de detecção de falhas em escadas rolantes, desta forma, serão exemplificados também outros sistemas relevantes à indústria metro-ferroviária, que utilizam sistemas inteligentes para a detecção de falhas, cuja filosofia possa ser adaptada às ERs.

Tsutada *et al.* (2005) do centro de pesquisa e desenvolvimento da Mitsubishi do Japão, desenvolveram um método que utiliza parâmetros estatísticos de som e vibração para diagnosticar falhas em ERs. Neste trabalho os autores instalaram em um degrau um microfone direcional e um acelerômetro de um eixo (vertical) para monitorar, através de uma rede sem fios e um computador, o funcionamento normal do equipamento, conforme pode-se observar na figura 2.3. De posse destes dados eles levantaram as curvas características e parâmetros estatísticos da ER sem falhas. Foram então introduzidos quatro tipos de falhas no equipamento: material estranho em trilho, rolamento de degrau danificado, perda de tensão na corrente principal de tração, material estranho nos suportes dos degraus. Os autores verificaram que durante as falhas, os parâmetros de som e vibração mudam dependendo do tipo de falha, desta forma, concluíram que é possível realizar o diagnóstico destas falhas através do modelo proposto.




Figura 2.3 – Modelo esquemático de Inspeção.

Fonte: Tsutada, 2005

No ano de 2007, os mesmos autores realizaram outro trabalho onde desenvolveram um método que verifica falhas na corrente principal de tração da ER através da vibração dos corrimãos. Este novo método de análise substitui o modelo convencional, onde o equipamento é parado para verificação da tensão manualmente. O modelo utiliza um dispositivo sem fios que é colocado sobre o corrimão da ER e envia os dados recolhidos a um computador, detectando automaticamente a tensão da corrente. Este dispositivo possui acelerômetros que medem a vibração nos corrimãos da ER no momento da partida da mesma, desta forma há diminuição da indisponibilidade do equipamento melhorando o desempenho da manutenção. Durante a inicialização do ER seu motor é acionado girando o conjunto redutor que tensiona a corrente principal, após isto um mecanismo gira a corrente de degraus que por sua vez move o corrimão. O sistema proposto mede as vibrações geradas no corrimão durante a inicialização da ER em sentido inverso ao normalmente utilizado, calculando os tempos de atraso entre as diversas etapas de inicialização. Desta forma é possível determinar eventuais folgas na corrente principal logo no princípio das falhas. Quando a ER encontra-se em funcionamento normal é determinado um padrão para as vibrações no corrimão, após isto o sistema compara as vibrações geradas com o modelo padrão indicando as possíveis falhas. Foram realizados testes em campo para comprovar a eficácia do método. Os autores relatam que o sistema proposto é eficiente e reduz o tempo gasto com esta manutenção a 10% do tempo gasto no sistema convencional.

Liu & Sin (1997) da Universidade Politécnica de Hong Kong, apresentam um trabalho desenvolvido para o metrô de Hong Kong que utiliza uma rede neuro-fuzzy para determinar a necessidade de manutenção do sistema de bloqueios, conhecidos popularmente como catracas. O artigo mostra uma forma de priorizar e planejar a manutenção destes equipamentos utilizando a lógica difusa para manipular o conhecimento explícito existente e redes neurais para mostrar o conhecimento implícito nos dados. Foram usados três métodos de treinamento de redes neurais para comparar qual a melhor opção para se chegar aos objetivos desejados: algoritmos genéticos, propagação rápida de erros e função de transferência senoidal. O sistema proposto utiliza onze tipos de dados diferentes para ser alimentado, desde dados estatísticos sobre a utilização dos equipamentos até dados climáticos como umidade e temperatura. Segundo os autores, após extensa análise, constatou-se que o modelo proposto é 20,08% mais eficiente que o método vigente para priorizar a manutenção destes equipamentos. O modelo mostrou-se bastante promissor, no próprio trabalho eles apontam que uma maneira de aperfeiçoar o método desenvolvido é estudar uma melhor forma de normalizar os dados adquiridos, bem como desenvolver um sistema mais completo que integre as funções de prevenção de falhas, análise de falhas e otimização de recursos com manutenção.

Joe Silmon e Clive Roberts do Centro de Educação e Pesquisa para ferrovias da Universidade de Birmingham apresentaram um novo método para detecção e prevenção de falhas em equipamentos mecânicos de movimentação única denominados *STME (Single-throw mechanical equipment)*. Este tipo de equipamento é muito utilizado na indústria metro-ferroviária como, por exemplo, AMVs (Aparelhos de Mudança de Via), portas de trens, bloqueios (catracas), etc. De forma geral são equipamentos que apresentam dois estados bem definidos (aberto/fechado, esquerda/direita). Esta peculiaridade pode ser utilizada para medir a forma de onda característica de atuação, pois durante a operação do equipamento ela é sempre parecida, mas não a frequência desta forma de onda, pois o intervalo entre atuações do equipamento não é sempre o mesmo. Os autores afirmam que esta abordagem é mais amigável para os operadores, pois os mesmos podem reconhecer facilmente as formas de onda, tanto do equipamento em perfeitas condições de funcionamento, como também em situações de falhas. Assim é possível determinar regras de desempenho de forma mais clara comparada com a utilização de outros métodos.

Foram determinados alguns parâmetros para o método proposto, tais como: detecção de falhas em estado inicial; utilização em vários tipos de STMEs; clareza para a equipe técnica; subsídios para ajudar a determinar parâmetros de manutenção. Foi feita uma revisão sobre formas de detecção de falhas utilizando sistemas baseados em modelos, onde é feita uma análise qualitativa das falhas, como também sistemas sem modelos de base, onde é feita uma análise quantitativa das falhas. O sistema proposto mescla todas estas formas de abordagem. Apesar das formas de onda serem ligeiramente diferentes cada vez que o equipamento é utilizado, devido às características eletromecânicas dos mesmos, eles desenvolveram um “alfabeto” composto por diversos tipos de formas de onda (equipamento com e sem falhas). Os dados coletados formaram as bases para o desenvolvimento de um conjunto de regras utilizando lógica difusa para que o sistema proposto pudesse ser usado em vários equipamentos diferentes. Os autores simularam o sistema proposto em laboratório, os testes reais utilizaram um único AMV para validar o sistema, onde simularam quatro tipos de falhas. Os dados iniciais indicam que o método é capaz de detectar falhas neste equipamento, porém não foram realizados testes para verificar se ele pode também ser usado em outros tipos de STME (SILMON, 2008).

Sob a responsabilidade e coordenação da UIC (*International Union of Railways* - União Internacional de Ferrovias), foi desenvolvido o projeto Innotrack (*Innovative Track Systems*), que reunia 36 associados de 11 países europeus, entre eles encontravam-se desde fabricantes de sistemas ferroviários, operadores de ferrovias e também universidades onde se desenvolvem pesquisas sobre este tema. (www.innotrack.net/article/partners). O objetivo deste projeto, segundo seus idealizadores, foi desenvolver soluções para a redução de custos nesta indústria em todos os seus níveis, desde a concepção dos sistemas até sua operação, passando também pelos custos de manutenção. Para isso, foram desenvolvidas quatro linhas de pesquisa: Estruturas de apoio à via; Chaves e travessões; Trilhos e material rodante, Logística para renovação e manutenção de vias. Atualmente este projeto foi encerrado, mas seus estudos e relatórios encontram-se disponíveis. (www.innotrack.net/article/presentation).

Dentro deste escopo, foi apresentado em 2009 um relatório sobre algoritmos para detecção e diagnósticos de falhas em equipamentos de mudança de via liderado por Joe Silmon da Universidade de Birmingham. Este trabalho foi elaborado durante

40 meses. O relatório é bastante detalhado e traça um perfil sobre os equipamentos de monitoramento automático para sistemas ferroviários, destacando que eles ainda estão em estágio inicial de desenvolvimento. O relatório é dividido em seis partes: nas duas primeiras é detalhado o cenário atual e os motivos que levaram a realização deste projeto; na terceira parte é mostrado o processo de aquisição e análise de dados relativos ao desempenho em condições normais e em modo de falha de um tipo de AMV comumente usado na Europa; na quarta parte é feita uma revisão sobre a literatura e os sistemas usados para diagnosticar falhas em sistemas metro-ferroviários; na quinta parte é apresentado um algoritmo que utiliza dados qualitativos e quantitativos para monitorar a corrente elétrica de alguns equipamentos identificando padrões e tendências, quando algum parâmetro monitorado é alterado, o sistema é capaz de identificar e prever falhas; na sexta parte é concluído o estudo e apresentado os resultados obtidos. É salientado pelos autores que existem diversas maneiras de realizar o monitoramento de sistemas, uns de maneira mais simples, outros mais complexos, uns com uso de muitos dados, simulações e conhecimentos técnicos apurados, outros com o uso de menos dados e mais amigáveis para com os usuários. É dito que o sistema por eles proposto utiliza uma quantidade pequena de dados e pode ser facilmente interpretado pelo corpo técnico das ferrovias (SILMON, 2009).

3. Teoria de Redes Neurais Artificiais

Neste capítulo serão abordados os fundamentos teóricos sobre Redes Neurais Artificiais (RNA). Será apresentado, com maiores detalhes, a RNA do tipo SOM - *Self Organizing Maps* (Mapa Auto-organizável) ou ainda rede auto-organizável de Kohonen.

3.1 Introdução

De acordo com Haykin (2001), de maneira geral uma RNA é uma máquina que é projetada para modelar a maneira que o cérebro realiza uma tarefa particular ou função de interesse. Ou seja, pode-se dizer que uma RNA é uma tentativa de simular a forma como o cérebro lida para solucionar problemas. De maneira simples pode-se representar o sistema nervoso como o diagrama de blocos descrito na figura 3.1.




Figura 3.1 - Diagrama de Blocos do sistema nervoso.

Fonte: Haykin, 2001

O cérebro é uma rede neural composta aproximadamente por 10 bilhões de neurônios e por 60 trilhões de sinapses ou conexões (SHEPHERD e KOCK, 1990). Os neurônios possuem uma grande variedade de formas e tamanhos em diferentes partes do cérebro. A figura 3.2 mostra a representação de um neurônio natural chamado de célula piramidal, ele é um dos tipos mais comuns de neurônios corticais. A célula piramidal tem uma enorme capacidade de interconexão, pois pode receber até dez mil ou mais contatos sinápticos, ela também pode se projetar a milhares de células alvo.




Figura 3.2 – Neurônio natural – Célula piramidal

Fonte: Haykin, 2001

Pode-se de maneira simplificada dizer que o neurônio natural recebe os sinais através de diversos dendritos, os processa e os envia ao axônio, que possui diversas terminações (ou sinapses), neste momento estes sinais podem ou não seguir adiante. Ao passar por um neurônio os sinais podem ser atenuados ou amplificados. Pode-se ainda afirmar que o cérebro é um sistema plástico, ou seja, se adapta a novos ambientes. Uma das formas que esta plasticidade se dá é através da criação de novas conexões sinápticas entre os neurônios e também através da modificação das conexões já existentes, ou seja, o processo chamado de aprendizagem se dá através das alterações das conexões sinápticas (HAYKIN, 2001).

O início dos estudos de RNA e também dos sistemas de inteligência artificial deu-se em 1943 com a publicação do artigo “*A logical calculus of the ideas immanent in nervous activity*” pelo neurofisiologista W.S. McCulloch e pelo matemático W. Pitts. Neste trabalho, estes pesquisadores propuseram o primeiro modelo matemático do funcionamento de um neurônio. Após este trabalho pioneiro, foram propostos diversos outros modelos de neurônios. A figura 3.3 mostra um modelo matemático de um neurônio.




Figura 3.3 – Modelo matemático de um neurônio.

Fonte: Haykin, 2001

Neste modelo observam-se os três principais elementos do neurônio, que são:

- Sinapses – que representam as entradas da rede multiplicadas por um peso sináptico (W). Sua representação típica é W_{kj} , onde k corresponde ao neurônio, j a uma entrada e W ao respectivo peso sináptico;
- Somador – Soma os sinais ponderados da entrada. Sua saída é representada por V_k . Este elemento, que é um combinador linear, também é chamado de campo local induzido ou ainda de potencial de ativação;
- Função de ativação (ϕ) – Tem a finalidade de assegurar que a saída do neurônio tenha um valor finito. Pode ser linear ou não linear. Tipicamente o intervalo de saída é 0 e 1, ou ainda -1 e 1.

Partindo-se desta estrutura temos as seguintes equações:

$$V_k = \sum_{j=1}^m W_{kj} \cdot X_j \quad (3.1)$$

$$Y_k = \phi(u_k + b_k) \quad (3.2)$$

onde $X_1, X_2, \dots, X_m$ representam os sinais de entrada, $W_{k1}, W_{k2}, \dots, W_{km}$ correspondem aos pesos sinápticos, V_k representa o campo local induzido, Y_k é a saída do neurônio, e ϕ a função de ativação. O termo B_k corresponde ao *bias*, aplicado externamente e tem o efeito de aumentar ou diminuir o nível da entrada da função de ativação.

Os neurônios, descritos acima, podem ser agrupados em camadas contendo um ou mais elementos. Suas saídas podem ser a saída do sistema, ou alimentar neurônios de outras camadas. Este conjunto de neurônios agrupados é chamado de rede neural artificial.

Em relação à arquitetura, existem três classificações das RNA, redes alimentadas adiante (*feedforward*) com camada única, rede alimentada adiante com múltiplas camadas e redes recorrentes. De forma geral, a arquitetura de uma RNA apresenta as seguintes características:

- Camada de entrada – Esta camada não possui nenhum neurônio. Apresenta uma quantidade de nós igual à quantidade de sinais de entrada da rede;
- Camada oculta – As RNA podem possuir, ou não, uma, duas ou diversas camadas ocultas de neurônios. A necessidade deste elemento é diretamente ligada à complexidade e a linearidade do problema em que a rede será aplicada;
- Camada de saída – Possui um número de neurônios igual à quantidade de sinais de saída da rede.

O processo em que as RNA são submetidas antes de iniciar sua operação, onde são apresentadas à rede algoritmos contendo o conjunto de dados da entrada e/ou os padrões desejados de saída é chamado de treinamento. O treinamento de uma RNA pode ser do tipo supervisionado ou não supervisionado.

No treinamento supervisionado o conhecimento a ser apresentado a RNA encontra-se em exemplos do tipo entrada-saída, onde modificando os pesos sinápticos o “treinador” pode diminuir o erro apresentado pela RNA em sua saída. Um exemplo desta arquitetura é a rede *Perceptron* de Múltiplas Camadas (PMC), ou *Multilayer Perceptron (MLP)*. As ideias iniciais sobre o *perceptron* podem ser vistas no trabalho de Rosenblatt, (1958).

Após a fase de treinamento, é necessário confirmar a capacidade de generalização da RNA. Para isto, é apresentado um novo conjunto de dados como entrada à RNA, diferente daquele usado anteriormente no treinamento; esta fase é chamada de fase de testes. Nela, é verificado se as saídas apresentadas são

compatíveis com os valores esperados. Em caso afirmativo, é dito que a RNA está treinada. Desta forma, ela possui a capacidade de apresentar saídas coerentes para dados diferentes daqueles usados durante a fase de treinamento. Caso os resultados obtidos sejam muito diferentes dos esperados, é necessário realizar um novo treinamento.

No treinamento não supervisionado não existe um “treinador” supervisionando o processo de aprendizagem, a RNA extrai as informações através dos dados de entrada apresentados, mas sem a indicação dos padrões de saída. Pode-se citar como exemplo de arquitetura auto-organizável as redes do tipo SOM *Self-Organizing Maps*. A proposta inicial desta arquitetura pode ser vista em Kohonen, (1982).

3.2 Rede Neural PMC

As RNA do tipo Perceptron de Múltiplas Camadas (PMC) são utilizadas com sucesso na resolução de projetos, sendo as mais utilizadas para classificação de padrões e controle e processamento de sinais (HAYKIN, 2001).

É ainda o tipo mais comum de RNA.

Uma RNA do tipo PMC é uma generalização do perceptron de camada única. É formada por um conjunto de nós não computacionais que formam a camada de entrada da rede, uma ou mais camadas ocultas e uma camada de saída. As camadas ocultas e a camada de saída são formadas por neurônios, desta forma apresentam capacidade computacional. Estas RNA são do tipo *feedforward*, ou seja, todas as saídas dos neurônios de uma camada anterior são conectadas unicamente as entradas dos neurônios da camada posterior, não ocorrendo realimentação na RNA. Assim um sinal de entrada se propaga através das camadas de maneira progressiva, seguindo o sentido da entrada para a saída. Na figura 3.4 pode-se ver o exemplo de uma PMC com uma camada de entrada, duas camadas ocultas e uma camada de saída, totalmente conectada. Diz-se que uma PMC é totalmente conectada quando um neurônio da rede é ligado a todos os nós/neurônios da camada anterior.




Figura 3.4 – Arquitetura de uma PMC com duas camadas ocultas.

Fonte: Haykin, 2001

3.3 Rede Neural SOM

O Mapa Auto-Organizável, ou *Self-Organizing Map* (SOM), é um tipo de RNA baseada em aprendizado competitivo e não supervisionado. Nela os neurônios de saída competem entre si para serem ativados. Desta forma, somente um deles está ligado em um determinado intervalo de tempo. Este neurônio é chamado neurônio vencedor (HAYKIN, 2001).

Este conceito foi desenvolvido em 1982 por Teuvo Kohonen e imita a ação das redes neurais biológicas, onde cada neurônio aceita diferentes sinais de neurônios vizinhos e os processa. Os mapas auto-organizáveis analisam dados por meio de agrupamentos com o objetivo de descobrir estruturas e padrões (KOHONEN, 1982).

Nas RNA tipo SOM, os neurônios são colocados em uma grade, normalmente uni ou bidimensionais. Durante o processo de aprendizagem são apresentados diversos estímulos a esta grade; o neurônio que melhor responder ao estímulo é o vencedor e tem seus pesos ajustados, assim são apresentados a RNA somente os padrões de entrada e gradativamente a rede monta um mapa topográfico para melhor representar estes dados (VESANTO *et al.*, 2000).

De acordo com Haykin (2001), os mapas auto-organizáveis, enquanto modelo neural, são inspirados na capacidade do cérebro humano de organizar diferentes estímulos nervosos em regiões distintas do *córtex* cerebral de forma ordenada topologicamente. Desta forma, o mapa computacional é definido por um conjunto de neurônios representando filtros ajustados de maneira ligeiramente diferente entre si, operando de maneira paralela. Neurônios que lidam com informações parecidas são localizados topologicamente próximos, de modo que suas conexões sinápticas sejam curtas. Assim os neurônios transformam a informação de entrada em uma distribuição da probabilidade da localização no mapa.

Na figura 3.5 observam-se dois modelos pioneiros de mapeamento de características, o modelo proposto por Willshaw e Von der Malsburgem (1976) e o proposto por Kohonen (1982), ambos são modelos bidimensionais baseados na característica de mapeamento neurobiológica. O modelo proposto por Willshaw e Von der Malsburgem é especializado em mapeamento no qual a dimensão de entrada é igual a de saída. Já no proposto por Kohonen isto não é necessário, podendo ocorrer a compressão de dados, ou seja, este modelo pode reduzir a dimensão da entrada, tornando-se mais generalista e de fácil trato computacional. Assim, de acordo com Haykin (2001) este é o principal motivo do modelo de Kohonen ser muito mais usado e discutido na literatura.




Figura 3.5 - Modelos de mapas auto-organizáveis de características.

Fonte: Haykin, 2001

3.3.1- Formação do Mapa Auto-Organizável

O principal objetivo de um mapa auto-organizável é transformar, de maneira gradativa, uma entrada com padrão arbitrário e aleatório em um mapa topologicamente organizado (HAYKIN, 2001).

A figura 3.6 mostra a organização típica de uma grade de entradas de um mapa auto-organizável. Nela observa-se que todos os neurônios estão em uma única camada computacional, organizados em linhas e colunas e totalmente conectados a entrada. Além disto, é possível observar que esta estrutura é do tipo alimentada adiante.




Figura 3.6 Grade Bidimensional de neurônios.

Fonte: Haykin, 2001

A formação de um mapa auto-organizável possui três etapas, a fase competitiva, a fase cooperativa e a fase adaptativa.

Na fase competitiva, para cada padrão de entrada, os neurônios da grade têm seus valores calculados por algum tipo de função discriminante, aquele que obtiver o maior valor para esta função é chamado de neurônio vencedor, ou em inglês BMU *Best Matching Unit* - (Unidade de Melhor Casamento).

As equações matemáticas que descrevem o neurônio vencedor são mostradas a seguir.

Considerando que M represente a dimensão do espaço de entrada, R^m , um padrão selecionado aleatoriamente nesse espaço é dado por (3.3).

$$x = [x_1, x_2, \dots, x_m]^T \quad (3.3)$$

O vetor peso sináptico de cada neurônio da grade tem a mesma dimensão do espaço de entrada. O vetor peso sináptico do neurônio j é representado por (3.4).

$$w_j = [w_{j1}, w_{j2}, \dots, w_{jm}]^T, \quad j=1, 2, \dots, I \quad (3.4)$$

onde I é o número total de neurônios na grade.

Para se determinar o neurônio que é mais parecido com a entrada x , basta comparar os produtos internos $w_j^T x$ para $j=1, 2, \dots, I$ e selecionar o maior deles. O critério de casamento do vetor x com o neurônio j baseado na maximização do produto interno é matematicamente equivalente a minimizar a distância euclidiana entre os vetores x e w_j . A determinação do neurônio com maior produto interno determina a localização onde a vizinhança topológica dos neurônios excitados deve ser centrada. O índice $i(x)$ será usado para identificar o neurônio que melhor casa com o vetor de entrada x . Esse índice é dado por (3.5).

$$i(x) = \arg \min_j \|x - w_j\|, \quad j=1, 2, \dots, I \quad (3.5)$$

O neurônio que satisfaz a equação (3.5) é o neurônio vencedor.

Na fase cooperativa o neurônio vencedor determina a localização espacial de uma vizinhança topológica de neurônios excitados, fornecendo assim a base para a cooperação entre os neurônios vizinhos. É nesta fase que é definida a vizinhança topológica capaz de ajustar com mais ênfase os neurônios mais próximos ao centro

da vizinhança e com menos ênfase os neurônios mais distantes. A equação (3.6) define o raio da grade dos neurônios.

$$\sigma(n) = \sigma_0 \exp\left(-\frac{n}{\tau_1}\right), \quad n = 0, 1, 2, \dots, \quad (3.6)$$

Para isso, a vizinhança topológica em torno do neurônio vencedor, deve ser simétrica em relação ao centro e decair suavemente com a distância lateral. A função que tipicamente é utilizada para definição da vizinhança é a gaussiana, que é dada pela equação (3.7).

$$h_{j,i(x)} = \exp\left(-\frac{d_{ji}^2}{2\sigma^2}\right) \quad (3.7)$$

onde: $h_{j,i(x)} \rightarrow$ Função de vizinhança para o vizinho j em relação ao vencedor i para o dado x , que determina o nível de cooperação;

$d_{ji} \rightarrow$ Distância lateral entre o vizinho j e o neurônio vencedor i ;

$\sigma \rightarrow$ Largura efetiva da vizinhança na interação.

Na fase adaptativa, os neurônios excitados aumentam os valores de sua função discriminante em relação ao padrão de entrada, por meio de ajustes em seus pesos sinápticos. Assim, é necessário que o vetor de peso sináptico w_j do neurônio j da grade se modifique em relação ao vetor de entrada x . Para isso o vetor peso sináptico $w_j(n)$ do neurônio j no tempo discreto n é ajustado pela equação (3.8) que foi definida por Kohonen (1992);

$$w_j(n+1) = w_{j(n)} + \eta(n)h_{j,i(x)}(n)(x - w_{j(n)}) \quad (3.8)$$

onde: $w_j(n)$ é o vetor de pesos sinápticos no tempo discreto n ;

$w_j(n+1)$ é o vetor de pesos atualizado, no tempo $n+1$;

$\eta(n)$ é o parâmetro taxa de aprendizagem dado por (3.8);

$h_{j,i(x)}$, é a função de vizinhança definida em (3.6);

x , é o vetor de entrada.

A equação tem o efeito de mover o vetor peso sináptico w_i do neurônio vencedor i em direção ao vetor x . A equação é aplicada a todos os neurônios que se encontram dentro da vizinhança topológica.

O parâmetro taxa de aprendizagem $\eta(n)$ é variável com o tempo e deve diminuir gradativamente. Para isso escolhe-se a taxa de aprendizagem com o decaimento dado pela exponencial (3.9).

$$\eta(n) = \eta_0 \exp\left(-\frac{n}{\tau_2}\right), \quad n=0, 1, 2, \dots, \quad (3.9)$$

onde: τ_2 é uma constante de tempo.

Os parâmetros apresentados nas equações acima podem receber infinitos valores para formarem o processo de auto-organização. Mas para uma representação ordenada dos padrões de entrada, esses parâmetros devem ser selecionados adequadamente.

O processo de adaptação sináptica, mostrado pela equação (3.7), é composto de duas fases. A fase de ordenação, ou organização, e a fase de convergência.

Durante a fase de organização do algoritmo SOM, que pode exigir ao menos 1000 iterações, a função de vizinhança deve incluir quase todos os neurônios da grade e a taxa de aprendizagem deve ser alta, para permitir uma aproximação mais rápida de neurônios semelhantes e definir a característica topológica do mapa. O parâmetro de taxa de aprendizagem nesta fase deve iniciar com um valor próximo de 0,1 e decrescer com o tempo, mas jamais deve chegar a zero, permanecendo sempre acima de 0,01. A função de vizinhança, deve inicialmente incluir todos os neurônios da grade, centralizados no neurônio vencedor e diminuir com o tempo. Para isto σ_0 deve ter ao menos o valor do tamanho do raio da grade. Já a constante de tempo τ_1 na equação (3.6) pode ser especificada conforme os valores iniciais abaixo.

Assim pode-se definir os valores iniciais da fase de organização como:

$$\begin{aligned} \eta_0 &= 0,1 & \tau_2 &= 1000 \\ \tau_1 &= \frac{1000}{\log(\sigma_0)} & \sigma_0 &= \text{raio da grade} \end{aligned}$$

A fase de convergência é uma espécie de sintonia fina do mapa, de modo a produzir uma quantização estatística precisa do espaço de entrada. Essa fase dura no mínimo 500 vezes o número de neurônios j da rede, podendo durar milhares de iterações, a taxa de aprendizagem aqui deve ser mantida em um valor pequeno, próximo de 0,01, mas não podendo nunca chegar a zero.

Desta forma, os valores iniciais da fase de convergência podem ser definidos da seguinte forma:

$$\eta_n = 0,01$$

$$\tau_2 = 500 \cdot j$$

3.4- Resumo do Algoritmo SOM

De acordo com Haykin (2001), o algoritmo SOM de Kohonen substitui por computação geométrica simples as propriedades detalhadas da regra hebbiana e interações laterais.

Os componentes essenciais ao algoritmo são:

Um espaço de entrada contínuo de padrões de ativação é gerado de acordo com uma certa distribuição de probabilidade;

Uma topologia da grade de neurônios que define um espaço de saída discreto;

Uma função de vizinhança variável no tempo e que é definida ao redor de um neurônio vencedor;

Um parâmetro de taxa de aprendizagem que começa com um valor relativamente alto e diminui com o tempo, mas nunca chega a zero.

Existem três passos básicos envolvidos na aplicação deste algoritmo após a inicialização do mesmo: amostragem; definição de um neurônio vencedor e atualização. Estes três passos são repetidos até a confecção final do mapa.

Assim pode-se resumir o algoritmo a cinco estágios:

1. *Inicialização*. Escolha de valores aleatórios para os vetores de peso iniciais. Ou de forma alternativa, selecionam-se os vetores de peso através de um conjunto

dos vetores de entrada

2. *Amostragem*. É retirada uma amostra x do espaço de entrada com uma certa probabilidade, este vetor representa o padrão de ativação dos neurônios da grade;

3. *Definição do neurônio vencedor*. Encontra-se o neurônio com a melhor similaridade no tempo definido. Para isto normalmente é utilizado o critério da mínima distância euclidiana;

4. *Atualização*. Ajusta-se os pesos dos vetores sinápticos utilizando a forma da atualização de Kohonen;

5. *Continuação*. Continue com o passo 2 até que não sejam observadas modificações significativas no mapa de características.

4. Materiais e Métodos

Neste capítulo são mostrados os materiais e a metodologia de coleta dos dados utilizados neste trabalho.

As ERs são equipamentos que possuem natureza multidisciplinar, pois engloba componentes mecânicos, elétricos e nas ERs mais modernas, eletrônicos, como por exemplo: corrente de tração; roletes de corrimão; coroa de corrente; caixa redutora de engrenagens; degraus; motor elétrico; sensores; clps; inversores de frequência; *etc.* Além disto, são sistemas multi-corpos e por este motivo de difícil modelagem matemática, conforme Cabanellas *et al.*, (2008) e Kwon *et al.*, (1998).

Existem diversos fatores que podem levar uma ER a parar seu funcionamento durante sua operação, tanto falhas de elementos pertencentes ao equipamento como os componentes mecânicos, elétricos ou eletrônicos, sinalizações corretas dos sensores de segurança da ER (falha real, neste caso realmente o equipamento deve parar), sinalizações incorretas dos mesmos sensores (falsa falha, neste caso ocorre a parada indevida da ER), ou ainda eventos externos ao equipamento, tais como atos de vandalismo. Como dito anteriormente, a parada brusca deste equipamento pode causar acidentes (Al-SHARIF *et al.*, 2012). Cerca de 68% das falhas em escadas rolantes na linha 5 da Companhia do Metropolitano de São Paulo (Metrô) tem causas desconhecidas. Além disto, por ser muito importante nos deslocamentos, os clientes de ERs necessitam que o tempo de parada deste equipamento para manutenção seja o menor possível (TERAZONO *et al.*, 1994).

De acordo com o corpo técnico do Metrô, uma das prováveis causas destas falhas de origem desconhecidas, pode ser a abertura de maneira rápida e com tempo extremamente curto das micro-chaves da linha de segurança das ERs causada por vibrações provenientes da passagem de usuários pelo equipamento nos horários de maior movimento das estações.

Em seu trabalho de 2005, Tsutada *et al.* propõem a análise de falhas em ERs através do sensoramento de um degrau e analisando aspectos de vibração no eixo Z e também do som. Porém este método tem o inconveniente de necessitar que um

degrau seja retirado e substituído por outro instrumentado. Além disto, os instrumentos utilizados são de custo elevado.

A fim de comprovar as alegações anteriormente mencionadas, foi desenvolvido neste estudo, um equipamento portátil e de baixo custo, que monitora as vibrações da ER em três eixos X, Y e Z, e grava estes dados em um cartão de memória para posterior análise. A figura 4.1 mostra o analisador de vibrações montado em seu suporte para fixação no degrau da ER e a indicação dos eixos medidos. A figura 4.2 mostra a parte interna do analisador.




Figura 4.1 - Analisador de vibração com indicação de eixos.




Figura 4.2 - Parte interna do Analisador de vibração.

Este registrador de vibração foi desenvolvido utilizando a plataforma de programação aberta Arduino, um microcontrolador ATmega 328P da Atmel (anexo E), um acelerômetro digital triaxial ADXL 345 da Analog Devices, (Anexo F), um cartão de memória do tipo SDHC I (*Security Digital High Capacity - Ultra High Speed*) de 16GB, além de um gravador de cartões do tipo SD. Ele é alimentado através de duas baterias TR18650 de 3,7V e 2500mAh, possuindo autonomia maior que 80 horas de gravações. O protótipo, em bancada, deste aquisitor de vibração pode ser visto na figura 4.3.




Figura 4.3 – Protótipo de analisador de vibração.

Durante a fase de estudos, além dos componentes finais utilizados neste projeto, foram realizados experimentos com acelerômetros analógicos, tipo ADXL 335 e cartões de memória do tipo SD. Mas os resultados obtidos foram inferiores aos dos componentes finais.

O acelerômetro digital ADXL 345 é configurável, tem uma resolução máxima de 13bits podendo medir uma aceleração de até $\pm 16g$ em três eixos. Já o acelerômetro analógico ADXL 335 tem como saída um sinal já condicionado de tensão, mede a aceleração máxima de $\pm 3g$ em três eixos.

Os cartões de memória tipo SD classe 4 podem trabalhar com a taxa máxima de 4MB/s de transferência, já os cartões SDHC I tem como taxa mínima 4MB/s de transferência. Porém estas velocidades dependem muito do barramento de informações e da taxa de latência do cartão.

4.1 Princípio de Funcionamento

Basicamente o funcionamento do registrador de dados é o seguinte:

- A vibração da ER é monitorada pelo acelerômetro ADXL 345;
- O microcontrolador ATmega 348P lê os dados do acelerômetro e os grava em um cartão SD.

De forma mais detalhada, o acelerômetro monitora a vibração da ER e a guarda em sua própria memória interna. O microcontrolador lê esta memória e a armazena em sua própria memória, após isto é criado um pacote de dados com estas informações que são enviadas para o leitor/gravador de cartões SD. Este por sua vez, localiza o arquivo que está sendo requisitado, o abre para gravações, acrescenta as informações enviadas, fecha o arquivo e envia a informação de confirmação de que está novamente disponível para ser requisitado.

A comunicação de dados entre o acelerômetro e o microcontrolador segue o padrão de comunicação *Inter-Integrated Circuit* (I²C). Entre o microcontrolador e o gravador de cartões SD, o padrão de comunicação é o *Serial Peripheral Interface* (SPI). A taxa de transferência de dados no I²C é menor que no SPI, ocorrendo portanto uma limitação de velocidade dos dados que trafegam no sistema.

Os dados que são lidos pelo acelerômetro são gravados em um arquivo contínuo do tipo .txt. A princípio este arquivo estaria limitado apenas pelo tamanho do cartão de memória utilizado. Porém, nos testes realizados, foi constatado que a utilização dos cartões SD para gravação de fluxo contínuo de informações tem um inconveniente. Conforme o arquivo de dados cresce, maior o tempo para que o cartão localize o final de arquivo e acrescente os dados, ou seja, quanto mais informações são acrescentadas, maior o risco de perda de informações.

O sistema de funcionamento das ERs é contínuo, seu ciclo de funcionamento pode ser medido de maneira periódica, mas esta periodicidade é baixa, em média uma ER completa seu ciclo em 65s, variando com o tamanho do desnível em que ela está instalada. Ou seja, sua frequência é de aproximadamente 15mHz.

Assim, devido às características mecânicas das ERs e para que não ocorra perda de dados, o registrador de dados foi parametrizado para realizar leituras a uma taxa de 400 amostras por segundo, e gravar os dados lidos no cartão a uma taxa de 90 amostras por segundo.

De maneira empírica, para facilitar o manuseio dos dados obtidos, bem como para minimizar o problema do tamanho dos arquivos gerados, definiu-se o tempo de dez minutos de gravação para cada arquivo gerado. A cada hora os mesmos são agrupados e separados em uma pasta dentro do cartão SD. Ou seja, a cada hora são gerados 6 arquivos de 10 minutos contendo os dados de vibração da ER.

Para a análise dos dados obtidos, foi utilizado o programa *computacional Matlab*.

Foram escritos dois algoritmos (*scripts*) (ANEXOS B e C) para análise dos dados, o primeiro apresenta os dados vibracionais de forma temporal, já o segundo utiliza a técnica de *Fast Fourier Transform* (FFT) para mostrar a amplitude das vibrações do ponto de vista da frequência em cada eixo analisado.

4.2 Procedimento de aquisição dos dados

Utilizando dados estatísticos sobre a frequência de ocorrências de falhas em ERs, foram escolhidos dois equipamentos para que o analisador de vibrações fosse inicialmente instalado. Foram analisadas 646 falhas em um período de um ano. O primeiro equipamento, ER1, apresenta baixos níveis de ocorrência de falhas, totalizando cinco falhas no período, sendo que apenas duas destas falhas foram finalizadas como tendo origem desconhecida. A ER1 está instalada em uma estação com baixo índice de usuários. Já o segundo equipamento escolhido, ER2, possui um alto índice de falhas, pois apresentou 41 falhas no mesmo período, sendo que deste total 31 falhas foram finalizadas como tendo origem desconhecida. Ou seja, em 76% das falhas apresentadas por este equipamento, no período analisado, não se pode diagnosticar a causa do defeito. A ER2 está localizada em um local com um grande fluxo de usuários. A figura 4.4 mostra o analisador instalado em uma ER e a orientação dos eixos analisados.



Figura 4.4 – Analisador instalado em uma ER.

O analisador de vibrações foi instalado nas duas ERs utilizando o seguinte procedimento:

Inicialmente as ERs encontravam-se paradas, pois se pretendia registrar o momento de partida dos equipamentos. Elas então foram ligadas no sentido de descida, após isto, o analisador ficou instalado por duas horas em cada ER;

Foram colhidos os dados de vibração destas ERs. Estes dados foram analisados e os resultados obtidos são apresentados no próximo capítulo.

5. Análise de Dados e Simulações Computacionais

Neste capítulo são apresentados os resultados obtidos com a análise dos dados de vibração coletados das ERs analisadas. É também apresentada a simulação de uma RNA tipo SOM a fim de verificar a viabilidade da mesma para separar e classificar os dados de vibração das ERs durante sua operação em diversos momentos do dia. Foram utilizadas as mesmas ERs citadas no capítulo anterior. ER1 com baixo índice de falhas e ER2 com alto índice de falhas. Todas as análises e simulações foram feitas utilizando o programa computacional *Matlab*.

Nas figuras 5.1 e 5.2, pode-se observar a vibração na ER1 e na ER2 nos três eixos analisados.




Figura 5.1 – Vibração nos eixos X, Y e Z da ER1.

Pela análise da figura 5.1, observa-se no ponto 1 o início do deslocamento da ER. Nos pontos 2 e 3, observa-se a inversão do analisador, pois o mesmo foi instalado na parte inferior dos degraus. Nestes pontos o degrau instrumentado passa por suas guias de recolhimento, conforme figura 1.1, e é girado em 180° , consequentemente ocorre a alteração do eixo de vibração. É possível notar que somente nestes pontos, ocorre uma pequena vibração no eixo X, possivelmente pelo menor atrito entre o degrau e a guia de recolhimento.

Conforme mencionado anteriormente, devido à natureza contínua de trabalho das ERs, após a saída do estado de repouso, o padrão de vibração se repete e é o mesmo em todo o tempo que o analisador de vibração ficou instalado.




Figura 5.2 – Vibração nos eixos X, Y e Z da ER2.

Através da análise da figura 5.2, observa-se no ponto 1 o início do deslocamento da ER. Nos pontos 2 e 3 o local em que o degrau instrumentado é recolhido. No ponto 4, a vibração proveniente do deslocamento dos usuários sobre a ER e no ponto 5, a aceleração no momento de recolhimento do degrau.

Comparando-se as figuras 5.1 e 5.2, observa-se que a vibração no eixo X na ER1 é de pequena amplitude e aparece somente no momento em que ocorre o recolhimento do degrau que o analisador está instalado. Já na ER2, a amplitude do sinal é maior e ocorre também em outros momentos, por exemplo, quando os usuários estão transitando sobre a ER. Além disto, observa-se que de forma geral, os gráficos da ER1 são mais “limpos” que os da ER2.

Nas figuras 5.3 e 5.4, observa-se a vibração na ER1 e na ER2 nos eixos X, Y e Z no espectro das frequências.




Figura 5.3 – Frequência de vibração ER1.

Na ER1 (figura 5.3), pode-se observar que na frequência de 0,014Hz, ocorrem os picos de amplitude de aceleração nos três eixos analisados. Sendo que no eixo X a amplitude é praticamente zero, já no eixo Y ela é de 0,42g e no eixo Z é de 0,94g.




Figura 5.4 – Frequência de vibração ER2.

Na ER2 (figura 5.4), observa-se que os picos de aceleração nos eixos X, Y e Z não são coincidentes, como observado suas amplitudes são diferentes, sendo que no eixo X é de 0,14g, no eixo Y é de 0,46g e no eixo Z o pico de amplitude de aceleração ocorre na frequência de 0,016Hz e é de 0,99g. Pode-se observar ainda que nos eixos Y e Z aparecem componentes harmônicos de aceleração.

Na figura 5.5, são mostrados dois ciclos de deslocamento da ER2 e é apresentado nos pontos 1 e 2, de forma destacada, o efeito do deslocamento dos passageiros nos eixos Y e Z neste equipamento.




Figura 5.5 – Efeito dos passageiros sobre a ER2 nos eixos Y e Z

A partir destes dados, pode-se observar que a vibração causada pelo deslocamento dos passageiros é percebida em ERs instaladas em estações de grande fluxo, pois o mesmo efeito não foi observado na ER1. Assim, esta vibração, pode ser um dos agentes causadores da maior incidência de falhas com causas não identificadas nestas ERs. Além disto, pela análise do horário das falhas estudadas, verificou-se que cerca de 90% das falsas falhas em estações de grande fluxo, ocorrem nos horários de alta movimentação de passageiros, ou seja, nos horários de pico de movimento das estações.

5.1 Análise de falhas

De posse dos dados iniciais e devido à alta incidência de falhas (F) na ER2, decidiu-se realizar uma análise mais detalhada dos seus dados de vibração. Assim o analisador de dados foi instalado por duas semanas consecutivas nesta ER. Nos primeiros dois dias, a ER foi deixada em funcionamento ininterrupto, nos demais dias, a ER era desligada no horário da 01h00 até as 4h30min. A cada dois dias foi realizada a substituição do cartão SD e das baterias que alimentam o analisador. Os dados coletados foram descarregados e analisados, tanto de forma temporal, como em relação a amplitude e frequência das vibrações.

As figuras 5.6, 5.7 e 5.8, mostram o padrão de vibração nos três eixos analisados desta ER no domínio do tempo em diversos horários do dia.




Figura 5.6 – Padrão de vibração ER2 sem usuários.

Na figura 5.6 é apresentado o padrão de vibração da ER às 02h00. Ou seja, sem nenhuma movimentação de usuários na estação. Nela pode-se observar somente as vibrações naturais desta ER. Os picos de aceleração que ocorrem no momento em que o analisador é recolhido, vistos nos pontos 1, 2 e 3 podem ser explicados devido ao desgaste nas guias de recolhimento dos degraus.

Na figura 5.7 o padrão apresentado é das 14h00. Ou seja, em horário de baixa movimentação sobre a ER. Nela pode-se observar uma vibração de pequena amplitude e baixa duração causada pelos usuários nos pontos 1, 2, 3, 4, 5 e 6.




Figura 5.7 – Padrão de vibração ER2 com baixa movimentação de usuários.




Figura 5.8 – Padrão de vibração ER2 com alta movimentação de usuários.

Na figura 5.8, é mostrado o padrão às 7h00. Ou seja, em pleno horário de pico de movimentação de passageiros. Nos pontos 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11 e 12, pode-se observar que existe uma vibração de grande amplitude e longa duração causada pelos usuários.

Durante o tempo em que o analisador ficou instalado nesta ER ocorreram cinco falsas falhas. Todas ocorreram no horário de alta movimentação de usuários na estação. A figura 5.9 mostra uma destas falhas, pode-se observar nos pontos 1, 2, 3, 4, 5, 6, 7, 8 e 9 uma vibração de grande amplitude ocasionada pelos usuários. Os pontos 10, 11 e 12 indicam o momento que a ER parou de funcionar. Os pontos 13, 14, 15, 16, 17 e 18 indicam a continuidade da movimentação dos passageiros, mesmo com a ER parada.




Figura 5.9 – Falha ER2.

Todas as falhas foram também analisadas em relação a amplitude de vibração do domínio das frequências em todos os eixos. Para esta análise, foram separados e comparados dois sinais. Para o primeiro deles, verificou-se o momento em que a falha ocorreu e separou-se os dois minutos anteriores a este ponto. O segundo trecho analisado, também com duração de dois minutos, é de um momento anterior a falha em que a ER estava funcionando normalmente. Por exemplo, na figura 5.9, observa-se que a falha ocorreu aproximadamente aos 5min e 15s, assim o primeiro trecho

analisado foi de 3min e 15s até 5min e 15s, o segundo trecho analisado foi de 0min e 15s até 2min e 15s. A figura 5.10 mostra a análise do eixo Z, nela estes dois trechos estão sobrepostos em um único gráfico.

Na figura 5.10 observa-se que os sinais de falha e de funcionamento normal são bastante semelhantes, eles apresentam pequenas variações de amplitude e frequência. Este tipo de resultado foi observado em todo o conjunto de falhas analisados.




Figura 5.10 – Falha ER2 – Frequências.

A figura 5.11, mostra intervalos de dois minutos de vibração da ER em três momentos do dia, quando a ER estava sem movimento de passageiros (SM), com baixo movimento de passageiros (BM) e com alto movimento de passageiros (AM). É possível observar que os sinais são semelhantes, mas diferentes ao longo do dia.




Figura 5.11 – Modelos de frequências da ER2 ao longo do dia.

5.2 Utilização de Mapas Auto-organizáveis.

Conforme observado anteriormente, os sinais provenientes da vibração em uma ER nos diversos momentos do dia, incluindo os momentos em que apresenta falha, são muito semelhantes. Desta forma são de difícil classificação, seja por meio de análise visual dos sinais no tempo ou pelo domínio da frequência, conforme visto na seção anterior.

A RNA tipo SOM, também conhecido por mapa de Kohonen, é usada para agrupamento de dados e mapeamento segundo suas características. (KOHONEN, 2001). Para isto, um conjunto de dados é dividido em grupos, ou *clusters*, baseados em características específicas intrínsecas ao grupo. Ou seja, são verificadas as semelhanças e diferenças dos elementos dentro de um grupo, para que seja realizada a separação dos mesmos. São apresentados a este tipo de RNA apenas os vetores de entrada, desta forma são também amplamente utilizadas para classificar sistemas (KOHONEN, 2013).

Para a criação da RNA utilizada neste trabalho usou-se a ferramenta *SOMtoolbox* do Matlab. Embora não seja distribuída com o próprio Matlab, ela é amplamente utilizada para o estudo de RNA tipo SOM. Esta ferramenta foi desenvolvida por uma equipe de pesquisadores do Laboratório de Computação e Ciência da Informação, da Universidade de Tecnologia de Helsinque na Finlândia e contou com a participação de diversos pesquisadores. A principal finalidade desta *Toolbox* é facilitar o estudo envolvendo as redes Kohonen. Maiores informações podem ser obtidas na página do projeto no seguinte endereço eletrônico <http://www.cis.hut.fi/projects/somtoolbox/about>.

De maneira empírica, foram realizados diversos experimentos para definir a configuração final da rede SOM. O objetivo foi determinar aquele que apresentasse os menores erros de dispersão ou quantização (qe) e de erro topográfico (te). Foram testados mapas de diferentes tamanhos, bem como vários valores para as épocas de treinamento, e também diferentes valores para os raios da grade.

Em relação a quantidade de amostras utilizadas no treinamento da RNA, definiu-se que no treinamento da rede seriam usadas cinco amostras de cada tipo de

sinal obtido (SM, BM, AM e F), pois nos dados capturados foram identificadas cinco falhas. Desta forma, a RNA foi testada com 20 amostras de sinais de vibração, cada um destes sinais tem a duração de 2 minutos. Conforme dito anteriormente, a frequência de amostragem dos sinais foi de 90 amostras por segundo, assim cada um dos vetores da matriz de treinamento da rede tem o comprimento de 9600 amostras.

De acordo com Vesanto *et al* (2000) o número de unidades, ou neurônios, padrão de um mapa segue a seguinte fórmula:

$$munits = 5 \times dlen^{0,54321}$$

onde: *munits*, é o número de neurônios do mapa;

dlen, representa a quantidade de amostras no mapa.

Para mapas pequenos o número de neurônios é igual a $0,25 \times munits$, para mapas médios é igual ao valor de *munits* e para mapas grandes é de $4 \times munits$ ou maiores. Como foram utilizadas 20 amostras o resultado padrão para o número de neurônios é de vinte e cinco unidades. Foram testados mapas pequenos com seis unidades, médios, grandes com cem e quatrocentas unidades. Os melhores resultados foram obtidos com mapas de tamanho grande contendo quatrocentas unidades. A distribuição dos neurônios foi feita em uma grade de vinte linhas por vinte colunas. Assim, os parâmetros do mapa foram definidos conforme a Tabela 1. Nela pode-se observar as configurações finais da rede.

Tabela 1- Parâmetros de Configuração RNA	
σ_1 = raio inicial	3
α_1 = taxa de aprendizagem	0,5
α_2 = taxa de aprendizagem fase de ajuste fino	0,05
Tamanho do mapa	20 x 20
Formato do mapa	Folha
Padrão de distribuição dos neurônios	Hexagonal
Vizinhança dos neurônios	Gaussiana
Épocas de treinamento	1000
Inicialização	Aleatória

Após o treinamento da RNA, o erro de dispersão (qe) obtido foi de 0,0044 e o erro topográfico (te) foi igual a zero.

5.3 Análise dos Mapas

Uma das principais formas de visualização dos mapas auto-organizáveis é através da visualização de sua matriz de distâncias unificadas (U-matrix). A figura 5.12 mostra a U-matrix da RNA após seu treinamento. A cor azul indica proximidade com os neurônios vencedores distribuídos na grade, já as cores verde, amarelo e vermelha indicam as bordas do agrupamento. A análise deste mapa mostra claramente a formação dos grupos.




Figura 5.12 - Matriz de distâncias Unificadas - U-matrix.

As figuras 5.13 e 5.14, mostram a distribuição dos neurônios vencedores no mapa. Na figura 5.13, utilizou-se uma escala de tons de cinza para mostrar os neurônios vencedores, onde valores mais claros indicam mais proximidade e valores mais escuros indicam maiores distâncias dos mesmos. As siglas utilizadas foram as mesmas anteriormente citadas. SM, para indicar amostras sem movimentação de usuários; BM, indica baixa movimentação de usuários; AM, indica alta movimentação de usuários e F, para indicar falhas.




Figura 5.13 - Distribuição dos neurônios vencedores.

Na figura 5.14, os neurônios vencedores das falhas foram destacados para uma melhor visualização.




Figura 5.14 - Distribuição dos neurônios vencedores.

Pela análise das figuras 5.12, 5.13 e 5.14 é possível observar que há uma distribuição das amostras de treinamento em toda a grade da RNA. Além disso, embora os sinais de vibração provenientes desta ER sejam muito próximos, a RNA conseguiu diferenciá-los e separá-los em neurônios distintos.

Foi utilizada a função *som_clustercolor* da *SOMtoolbox* para colorir cada agrupamento da RNA, a figura 5.15 mostra o resultado desta operação. Pode-se observar a formação de nove agrupamentos e que mesmo sinais vibracionais diferentes foram colocados em grupos semelhantes. A região 1 agrupa sinais do tipo BM e F; a região 2 agrupa sinais do tipo AM e F; as regiões 3, 6 e 7 do tipo SM; as regiões 4 e 8 sinais do tipo BM e AM; a região 5 sinais do tipo BM e F e a região 9 sinais do tipo SM, BM e F. É importante notar que mesmo os grupos contendo elementos de natureza distinta as falhas ficaram sempre próximas dos elementos de alto movimento. Desta forma pode-se verificar que o treinamento da RNA foi satisfatório, uma vez que não ocorreu sobreposição de sinais.




Figura 5.15 - Formação dos agrupamentos (clusters) da RNA.

A fim de verificar a capacidade de generalização da RNA, foram separadas cem amostras aleatórias, diferentes daquelas usadas na fase de treinamento, com duração de dois minutos de diferentes horários de funcionamento da ER. A distribuição das amostras é mostrada a seguir:

100 amostras coletadas no período compreendido entre 01h00 e 04h00;

100 amostras coletadas no período compreendido entre 06h30 e 09h30;

100 amostras coletadas no período compreendido entre 14h00 e 16h00.

Além disto, foram também utilizadas as amostras de falhas adquiridas neste estudo. Os critérios para a escolha dos horários das amostras seguem o padrão de distribuição do movimento de passageiros ao longo do dia na estação do Metrô SP, em que a ER estuda está localizada.

Para esta verificação foram calculados, através da função *som_bmus* os neurônios vencedores para cada uma das amostras. Após isto, verificou-se a que agrupamento cada um destes neurônios pertencia. Os resultados encontrados são apresentados na tabela 2.

Tabela 2- Amostras gerais por região da RNA

Região	SM	BM	AM	F
1	21	15	12	1
2	3	15	13	2
3	15	7	5	0
4	0	14	12	0
5	0	11	12	1
6	13	6	8	0
7	25	11	12	0
8	0	12	9	0
9	23	9	17	1

Devido as características de fluxo de usuários, existem momentos em que não há trânsito de passageiros nas ERs. Assim, quando analisados intervalos de tempo

relativamente curtos, mesmo em horários de muito movimento, o padrão de vibração da ER é parecido com visto na figura 5.6. Ou seja, para estes intervalos o comportamento vibracional não apresenta a influência da passagem dos usuários. Isto pode ser visto comparando-se as figuras 5.7 e 5.8 com a figura 5.6. Igualmente em determinados momentos a vibração provocada pelos passageiros em horários de BM podem ter padrões de comportamento como os de AM. Por exemplo, quando um trem chega à estação, diversos passageiros podem descer do mesmo e utilizar a ER. Assim, dependendo da quantidade de passageiros seu comportamento vibracional pode ser classificado como de AM.

Do ponto de vista do trabalho proposto isto é uma vantagem, pois a RNA separou os sinais pelo padrão de vibração, e não por um critério temporal.

Foi elaborado um novo mapa com a função *som_hits* para verificar a distribuição dos sinais dentro da rede. A figura 5.16 apresenta a distribuição dos neurônios vencedores dos dados de generalização analisados, bem como a frequência de aparecimento dos mesmos nas diversas regiões do mapa.




Figura 5.16 - Distribuição dos neurônios vencedores, utilizando os dados de generalização.

Na figura 5.16 observa-se que a maioria das amostras está em zonas de limites dos agrupamentos, isto indica a similaridade destas amostras.

A tabela 3 foi elaborada após análise dos neurônios vencedores (Tabela 2) e da distribuição das amostras pelo mapa (Figura 5.16). Assim é apresentada a quantidade de amostras confundidas com falhas separadas por tipo.

Tabela 3 - Taxa de acerto por amostras gerais da RNA

Amostra	Acertos	Erros	% de acertos
SM	77	23	77
BM	82	18	82
AM	74	26	74
Desempenho geral			77,67

Analizando a porcentagem de erro ocorrida com cada tipo de amostra, verifica-se que a RNA apresentou um resultado global de 77,67% de acertos. O que foi considerado satisfatório dada à similaridade das amostras. Conforme pode ser observado na figura 5.11.

A fim de comparar o desempenho da rede SOM proposta, foi usado o mesmo conjunto de dados de entrada em RNA do tipo PMC treinada com o algoritmo *backpropagation* e arquiteturas do tipo 1x2x1 e variado número de neurônios em cada camada. Ou seja, compostas por uma camada de entrada, duas camadas intermediárias e uma camada de saída, sendo que o número de neurônios em cada camada variou entre um e vinte. Porém os testes não foram satisfatórios, uma vez que durante a fase de treinamento as RNAs testadas não convergiram para um resultado de saída.

6. Conclusões e Sugestões para Trabalhos Futuros

Pode-se afirmar que os objetivos propostos para a realização deste trabalho foram alcançados. Foi desenvolvido um instrumento de baixo custo capaz de medir a vibração e consequentemente verificar as assinaturas de funcionamento de uma ER. O custo total do analisador de vibrações foi de aproximadamente R\$250,00.

Observando-se os dados obtidos através do analisador de vibrações, utilizando os algoritmos desenvolvidos neste trabalho, foi possível constatar a influência da movimentação dos usuários sobre as ERs. Assim, através do cruzamento das informações dos horários em que a maioria das falsas falhas ocorreram, somado ao conjunto dos dados obtidos pelo analisador de vibrações, pode-se concluir que as vibrações provenientes do fluxo de passageiros influenciam na incidência destas falhas.

A RNA do tipo SOM desenvolvida neste trabalho, foi treinada utilizando-se os dados de vibração coletados e transformados em vetores para a matriz de treinamento da rede. Apesar dos sinais vibracionais serem muito parecidos, a RNA mostrou-se eficaz na separação e classificação das amostras. Utilizando-se os dados obtidos em diversos momentos do dia, a RNA conseguiu classificá-los e separá-los de forma satisfatória, obtendo 77,67% de êxito nesta tarefa.

Conclui-se, portanto, a viabilidade do uso desta técnica de inteligência artificial neste importante equipamento da indústria metro-ferroviária.

6.1- Sugestões para Trabalhos Futuros

Os estudos aqui desenvolvidos foram iniciais, podendo ser desenvolvidos em diversos aspectos, algumas sugestões:

Uma das propostas para melhoria do trabalho é aperfeiçoar o analisador de vibrações. O mesmo mostrou-se eficaz para o problema aqui estudado, porém ele pode ser melhorado de forma a gravar mais amostras de dados;

Outra sugestão é utilizar o analisador de vibrações em estudos de confiabilidade de equipamentos. Desenvolvendo assim um instrumento de manutenção preditiva. Pois sendo um instrumento desenvolvido com baixo custo sua utilização pode ser viável em outros sistemas além de ERs;

Pode-se também desenvolver um estudo para a implementação desta RNA em um equipamento que realize a análise dos dados em tempo real, podendo não só classificar as falhas como tomar decisões sobre o momento ou não de parada da ER;

Pode-se ainda estudar formas de melhorar o desempenho geral do sistema proposto. Por exemplo, testar a viabilidade do uso de outros tipos de topologias de RNAs, com o objetivo de obter índices maiores de acertos em relação a separação e classificação das falhas.

7. Bibliografia

AL-SHARIF, L., DADO, M., HABASH, N., RAWASHDEH, Z., AL-SHUBBAK, A., “Modeling and Verification of the Kinematics of passenger falls on escalators”, *Simulation* 2012 88, p. 988, Fevereiro, 2012.

AMES, N., “Revolving Stairs” *Patente 25076*, USA, 1859.

BLACKBURNE, F.W., “Escalator Safety Device” *Patente 1 695 083*, USA, 1926.

BRAGA, A. P., LUDEMIR, T. B., CARVALHO, A. C., “Redes Neurais Artificiais: Teoria e Aplicações”, LTC, Rio de Janeiro, 2000.

CABANELLAS, J. M., CANO-MORENO, J.D., SUÁREZ, B., CHOVER J.A., FÉLEZ, J., “Methods for Improving Escalators”, *Elevator Technology* 17, *Proceedings of Elevcon 2008*, pp 22-33, 2008.

CANO-MORENO, J.D., CABANELLAS, J. M., TIRADO, C.L., MINDÁN, J. F., “Methodology for Flexible Modelling of Escalator Multibody Systems”, *Industrial Simulation Conference*, Loughborough (UK), 2009.

CANO-MORENO, J.D., CABANELLAS, J. M., TIRADO, C.L., MINDÁN, J. F., “Methodologies for Designing and Developing New Concepts in Vertical Transportation”, *Revista Elevator World*, USA, Dezembro 2012.

HAYKIN, S., “Redes Neurais: Princípios e Prática”, 2ª Edição, Bookman, Porto Alegre, 2001.

HINTON, G. E., “Conenctionist Learning Procedures”, *Artificial Intelligence*, v.40, p. 185-234, 1989, *apud* HAYKIN, S., “Redes Neurais: Princípios e Prática”, 2ª Edição, Bookman, Porto Alegre, 2001.

INNOTRACK – “*Innotrack partners*” (Parceiros Innotrack) – Disponível em (www.innotrack.net/article/partners), acesso em 01/06/2015.

INNOTRACK – “*Innotrack presentation*” (Apresentação Innotrack) – Disponível em (www.innotrack.net/article/presentation), acesso em 01/06/2015.

SOMtoolbox - disponível em (<http://www.cis.hut.fi/projects/somtoolbox/about>), acesso em 08/07/2015

JOHN, G., “Escalator Brake” *Patente 1 200 502*, USA, 1913.

KOHONEM, T., "Essentials of the self-organizing map", *Neural Networks*, n.37, p. 52-65, 2013.

KOHONEN, T. "Analysis of a simple self-organizing process.", *Biological cybernetics*, v. 44, n. 2, 1982.

KOHONEN, T., "Self-organizing maps", Springer Science & Business Media, 2001.

KOHONEN, T., "The self-organizing map", *Proceedings of the Institute of Electrical and Eletronics Engineers* v.78, p. 1464–1480, 1990, *apud* HAYKIN, S., "Redes Neurais: Princípios e Prática", 2ª Edição, Bookman, Porto Alegre, 2001.

KWON, I.Y., "A Case Study of Multibody Dynamics Software Development Process by Adopting Lead Users Inovations. (With an Example of Escalator Modeling Application)" – 2012.

KWON, Y.S., "Dynamic Analysis Step-by-Step", *Mechanical Engineering-CIME*, 1998.

KWON, Y.S., COPELAND, G.S., PARK, N.G., "A Multibody Dynamic Model for Escalator Handrail Systems and its Application to Dynamic Characteristics", *Multibody System Dynamics*, n. 13, p. 253-266, 2005.

LIU, J.N.K., SIN, K.Y., "Fuzzy Neural Networks for Machine Maintenance in Mass Transit Railway System", *IEEE Transactions on Neural Networks*, v. 8, n.4, 1997.

MCCULLOCH, W.S., PITTS, W., "A Logical Calculus of the Ideas Immanent in Nervous activity", *Bulletin of Mathematical Biophysics*, v.5, p.115-133, 1943.

PINTO, A. K., Xavier, J. N., "Manutenção: função estratégica", Qualitymark Editora, Rio de Janeiro, 1999.

RADCLIFFE, A., "Escalator" *Patente 1 682 052*, USA, 1926.

ROSENBLATT, F., "The perceptron: A Probalistic Model for Information Storage and Organization in the Brain", *Psychological Review*, v.65, p.386-408, USA, 1958, *apud* HAYKIN, S., "Redes Neurais: Princípios e Prática", 2ª Edição, Bookman, Porto Alegre, 2001.

SHEPHERD, G.M., KOCH, C., "Introduction to Synaptic Circuits", *The Synaptic Organization of the Brain*, 3ª Edição, Oxford University Press, Nova York, 1990.

SILMON, J., *et al.*, "D3.3.4 Algorithms for Detection and Diagnosis of Faults on S&C", *Relatório para INNTRACK*, Junho de 2009.

SILMON, J., ROBERTS, C., " A Systems-Engineered Intuitive Adaptative, Failure Prediction System", *Proceedings of the Fourth IET International Conference on*

Railway Condition Monitoring, Derby (Uk), 18-20 de Junho de 2008.

TERAZONO, N., MATSUKURA, Y., "High Technology in Elevator", Ohmsha, Japão, 1994.

TSUTADA, H., HIRAI, T., ITOH, Y., SHIGA, S., "Chain Fault Detection of Escalator Using Handrail Vibration", *Proceedings of the Fourteenth International Congress of Sound and Vibration (ICSV14)*, Cairns, Australia, 9-12 Julho 2007.

TSUTADA, H., HIRAI, T., ITOH, Y., SHIGA, S., "Fault Diagnosis for Escalator Using Statistical Parameter of Sound and Vibration", *Proceedings of the Twelfth International Congress of Sound and Vibration (ICSV12)*, Lisboa, Portugal, 11-14 Julho 2005.

VESANTO, J.; HIMBERG, J.; ALHONIEMI, E.; PARHANKANGAS, J. "Self-organizing map in Matlab: the SOM Toolbox" *Laboratory of Computer and Information Science, Helsinki University of Technology*, Finlândia, 2000.

WOODWARD, G.E., "Conveyer" *Patente 1 659 968*, USA, 1925.

APÊNDICE A - Programa do Analisador de Vibrações desenvolvido na plataforma Arduino.

```

/*
Este programa utiliza as bibliotecas:

wire.h - para comunicação com o acelerômetro

SD.h - para utilização de comandos

SPI.h - para comunicação com o leitor/gravador de cartões SD

*/

#include <Wire.h>

#include <SD.h>

#include<SPI.h>

#define DEVICE (0x53) //ADXL345 endereço do acelerômetro

#define TO_READ (6) //Num de bytes sendo lidos por vez(2 bytes por eixo)

#define FIFO (0x38) //Definição de como os dados do acelerômetro são lidos

int seg = 0, min = 0, hor = 0, troca = 0, t_hor; // definição das variáveis

const int chipSelect = 4;

byte buff[TO_READ] ; //buffer de 6 bytes para salvar os dados vindos do acelerômetro

char str[96]; // buffer de string para transformar os dados antes de enviá-los ao cartão SD

char narquivo[12]; // buffer para guardar o nome do arquivo

char dir[12]; //contém o nome do diretório

char caminho[18]; //contém o caminho do diretório

int qtdarquivo = 0; // armazena o número do arquivo

File dataFile; // define o tipo de arquivo

// Função para escrita no acelerômetro

```

```

void writeTo(int device, byte address, byte val) {

    Wire.beginTransmission(device); //inicia a transmissão para o acelerômetro

    Wire.write(address);    // envia o endereço do registrador

    Wire.write(val);        // envia o valor a ser escrito

    Wire.endTransmission(); // termina a transmissão

}

// Função para leitura no acelerômetro

void readFrom(int device, byte address, int num, byte buff[]) {

    Wire.beginTransmission(device); //inicia a transmissão

    Wire.write(address);    //envia o valor lido

    Wire.endTransmission(); //termina a transmissão

    Wire.beginTransmission(device); //start transmission to device (initiate again)

    Wire.requestFrom(device, num); // requisita 6 bytes do acelerômetro

    int i = 0;

    while (Wire.available()) //o acelerometro pode enviar menos do que o solicitado (anormal)
    {

        buff[i] = Wire.read(); // recebe 1 byte

        i++;

    }

    Wire.endTransmission(); //termina a transmissão

}

//Ajustes

void setup()

{

    Wire.begin(); // inicia a conexão com o barramento i2c (endereço opcional para o master)

    Serial.begin(9600); // inicia a comunicação serial para a saída

```

```

//Ajustes do acelerômetro

writeTo(DEVICE, 0x2D, 0); // zera o registrador de controle de energia

writeTo(DEVICE, 0x2C, 15); // define o acelerômetro para trabalhar com amostras de 800Hz

writeTo(DEVICE, 0x2D, 8); // Coloca o acelerometro em modo de medição

writeTo(DEVICE, 0x31, 9); // Sensibilidade do acelerometro em 4g

writeTo(DEVICE, 0x1E, -5); // Ajuste de offset eixo x

writeTo(DEVICE, 0x1F, 4); // Ajuste de offset eixo y

writeTo(DEVICE, 0x20, 6); // Ajuste de offset eixo z


//Ajustes do leitor/gravador de cartões SD

Serial.print("Iniciando o cartão SD...");


pinMode(10, OUTPUT);


// verifica se o cartão SD está presente e foi inicializado:
if (!SD.begin(chipSelect)) {

    Serial.println("Cartão com defeito ou não inserido");

    // caso ocorra um erro, nada mais é feito:

    return;

}

Serial.println("cartão inicializado.");


// Cria o primeiro diretório

sprintf(dir, "hora%d", hor);

SD.mkdir(dir);

sprintf(caminho, "hora%d/vib%d.txt", hor, qtdarquivo);

}

```

```

// Rotinas de repetição

void loop()

{

    while (troca == 1) {

        sprintf(caminho, "hora%d/vib%d.txt", hor, qtdarquivo);

        // Se o caminho existir grava o arquivo

        if (SD.exists(caminho)) {

            qtdarquivo++;

        }

        // Se não existir acrescenta um diretório

        else {

            sprintf(dir, "hora%d", hor);

            SD.mkdir(dir);

            troca--;

        }

    }

    //-----

    //Rotinas de tempo

    static unsigned long ult_tempo = 0;

    int tempo = millis();

    if (tempo - ult_tempo >= 1000) { // ajuste de tempo

        ult_tempo = tempo;

        seg++;

    }

    if (seg >= 60) {

        seg = 0;

        // troca++;

        min++;
    }

```

```

}

if (min >= 10) {
    min = 0;

    troca++; // altera o arquivo de log a cada 10 minutos
t_hor++;
}

if (t_hor >= 6) {
t_hor = 0;

    qtdarquivo = 0;

    hor++;
}

//-----

//Rotinas de leitura

int regAddress = 0x32; //primeiro registrador do eixo de aceleração ADXL345
int x, y, z;

readFrom(DEVICE, regAddress, TO_READ, buff); //Lê a aceleração do ADXL345

//Cada leitura d eixo tem 10 bits de resolução, mas em 2 bytes. LSB primeiro!!

//temos que converter os dois bytes em um int
x = (((int)buff[1]) << 8) | buff[0];
y = (((int)buff[3]) << 8) | buff[2];
z = (((int)buff[5]) << 8) | buff[4];

//-----

//Rotinas de gravação

```

```
//conversao dos dados em string

sprintf(str, "%05d %05d %05d %02d %02d", x, y, z, min, seg);


//Lê a aceleração do ADXL345

readFrom(DEVICE, regAddress, TO_READ, buff);

// Verifica de o diretório existe e está disponível

dataFile = SD.open(caminho, FILE_WRITE);

// Se o arquivo estiver disponível, grava os dados.

if (dataFile) {

    dataFile.println(str);

dataFile.close();

}

}
```

APÊNDICE B – Algoritmo do Matlab para análise de vibrações no tempo.

```
%Algoritmo utilizado para avaliar a vibração no tempo
%

%Inicio
clear %Limpando as variáveis.
clc %Limpando a tela.
close all %Fechando as figuras abertas.

Fs =5200; % Frequência de amostragem
T = (1/Fs); % Tempo
L = length (x(:,1)); % Comprimento da amostra
t = (0:L-1)*T; % Vetor de tempo

%Normalizando as amostras
X = (x/256); % Função com amostras do eixo x
Y = (y/256); % Função com amostras do eixo y
Z = (z/256); % Função com amostras do eixo z

%Plotando as amostras no tempo.

figure(1) %Abre nova figura.
% Abre um subplot com 3 áreas
subplot(3,1,1), plot (t,X) % Plotando a 1° área. Eixo X
title('Vibração no eixo X') % Adicionando o título
ylim ([-4 4]) % definindo os limites do eixo y
grid % Adicionando linhas de grade
subplot(3,1,2), plot (t,Y,'r') % Plotando a 2° área. Eixo Y
title('Vibração no eixo Y') % Adicionando o título
ylim ([-4 4]) % definindo os limites do eixo y
ylabel('Aceleração (g)') % Adicionando o título do eixo y do gráfico
grid % Adicionando linhas de grade
subplot(3,1,3), plot (t,Z,'g') % Plotando a 3° área. Eixo Z
title('Vibração no eixo Z') % Adicionando o título
ylim ([-4 4]) % definindo os limites do eixo y
xlabel ('Tempo (min)') % Adicionando o título do eixo x do gráfico
grid % Adicionando linhas de grade

%Plotando cada eixo analisado de forma individual.

figure(2) %Abre nova figura.
plot(t,X) % Plotando o Eixo X
title('Vibração no eixo X') % Adicionando o título
ylim ([-4 4]) % definindo os limites do eixo y
ylabel('Aceleração (g)') % Adicionando o título do eixo y do gráfico
xlabel ('Tempo (min)') % Adicionando o título do eixo x do gráfico
grid % Adicionando linhas de grade

figure(3) %Abre nova figura.
plot(t,Y,'r') % Plotando o Eixo Y
title('Vibração no eixo Y') % Adicionando o título
ylim ([-4 4]) % definindo os limites do eixo y
ylabel('Aceleração (g)') % Adicionando o título do eixo y do gráfico
```

```
xlabel ('Tempo (min)')    % Adicionando o título do eixo x do gráfico
grid                     % Adicionando linhas de grade

figure(4) %Abre nova figura.
plot(t,Z,'g')            % Plotando o Eixo Z
title('Vibração no eixo Y') % Adicionando o título
ylim ([-4 4])            % definindo os limites do eixo y
ylabel('Aceleração (g)') % Adicionando o título do eixo y do gráfico
xlabel ('Tempo (min)')    % Adicionando o título do eixo x do gráfico
grid                     % Adicionando linhas de grade
```

APÊNDICE C - Algoritmo *Script* do Matlab para análise de vibrações na frequência.

```
%Algoritmo utilizado para avaliar a vibração na frequência
%

%Inicio
clear %Limpando as variaveis.
clc %Limpando a tela.
close all%Fechando as figuras abertas.

Fs = 90; % Frequência de amostragem
T = 1/Fs; % Tempo
a= [27276:37273]; %Definição do trecho a ser analisado
L = length (x(a)); % Comprimento da amostra

%Criação do vetor de tempo.
t = (0:L-1)*T;
%Normalizando as amostras
x1 = (x(a)/256); % Função com amostras do eixo x
y1 = (y(a)/256); % Função com amostras do eixo y
z1 = (z(a)/256); % Função com amostras do eixo z

%Convertendo para o domínio das frequências
NFFT = 2^nextpow2(L); % Calcula a próxima potência de 2 do comprimento na
da mostra.
f = Fs/2*linspace(0,1,NFFT/2+1);
X = fft(x1,NFFT)/L; % Cálculo para o eixo X
Y = fft(y1,NFFT)/L; % Cálculo para o eixo Y
Z = fft(z1,NFFT)/L; % Cálculo para o eixo Z

% Plotando os resultados das amplitudes do espectro.

figure(1)%Abre nova figura.
% Abre um subplot com 3 áreas
subplot(3,1,1), plot(f,2*abs(X(1:NFFT/2+1))) % Plotando a 1° área.
Eixo X
xlim ([0 3]) % definindo os limites
do eixo x
grid % Adicionando linhas de
grade
title('Espectro de freqüência unilateral eixo X') % Adicionando o título
subplot(3,1,2), plot(f,2*abs(Y(1:NFFT/2+1)),'r') % Plotando a 2° área.
Eixo Y
xlim ([0 3]) % definindo os limites
do eixo x
grid % Adicionando linhas de
grade
title('Espectro de freqüência unilateral eixo Y') % Adicionando o título
ylabel('|Aceleração| (g)') % Adicionando o título
do eixo y do gráfico
subplot(3,1,3), plot(f,2*abs(Z(1:NFFT/2+1)),'g') % Plotando a 3° área.
Eixo Z
xlim ([0 3]) % definindo os limites
do eixo x
```

```

grid                                     % Adicionando linhas de
grade
title('Espectro de freqüência unilateral eixo Z') % Adicionando o título
xlabel('Frequência (Hz)') % Adicionando o título
do eixo x do gráfico

%Plotando cada eixo analisado de forma individual.

figure(2)%Abre nova figura.
plot(f,2*abs(X(1:NFFT/2+1))) %Plotando o Eixo X
title('Espectro de freqüência unilateral eixo X') % Adicionando o título
xlabel('Frequência (Hz)') % Adicionando o título do eixo x do gráfico
ylabel('|Amplitude| (g)') % Adicionando o título do eixo y do gráfico
ylim ([0 1]) % definindo os limites do eixo y
xlim ([0 3]) % definindo os limites do eixo x
grid % Adicionando linhas de grade

figure(3)%Abre nova figura.
plot(f,2*abs(Y(1:NFFT/2+1)),'r')%Plotando o Eixo Y
title('Espectro de freqüência unilateral eixo Y') % Adicionando o título
xlabel('Frequência (Hz)') % Adicionando o título do eixo x do gráfico
ylabel('|Amplitude| (g)') % Adicionando o título do eixo y do gráfico
xlim ([0 3]) % definindo os limites do eixo x
grid % Adicionando linhas de grade

figure(4)%Abre nova figura.
plot(f,2*abs(Z(1:NFFT/2+1)),'g')%Plotando o Eixo Z
title('Espectro de freqüência unilateral eixo Z') % Adicionando o título
xlabel('Frequência (Hz)') % Adicionando o título do eixo x do gráfico
ylabel('|Amplitude| (g)') % Adicionando o título do eixo y do gráfico
xlim ([0 3]) % definindo os limites do eixo x
grid % Adicionando linhas de grade

```

APÊNDICE D - Algoritmo *Script* do Matlab para análise e desenvolvimento da RNA SOM

```
%Script utilizado nas simulacoes do trabalho
%
%Nesse algoritmo foi utilizado o SOMTOOLBOX para MATLAB:
%
% SOM Toolbox
% Version 2.0beta, May 30 2002
% Copyright 1997-2000 by
% Esa Alhoniemi, Johan Himberg, Juha Parhankangas and Juha Vesanto
% http://www.cis.hut.fi/projects/somtoolbox/
%
%Inicio
clear %Limpando as variáveis.
clc %Limpando a tela.
close all%Fechando as figuras abertas.

%Leitura dos dados do arquivo de treino.
dados = som_read_data('treino.data');

%Criando a estrutura dos dados.
sDs = dados;
D=dados.data;

%Normalizando os dados.

sDn = som_normalize(sDs,'var');

nl = 20; %Numero de linhas de neuronios.
nc = 20; %Numero de colunas de neuronios.

%Criando o mapa.

sMap = som_make(sDn,'randinit','msize',[nl nc],'name','Vibrações ER');

% Iniciando o treinamento
sMap= som_seqtrain(sMap,sDn,'trainlen',1000);

%Rotulando o mapa.
sMap = som_autolabel(sMap,sDn);

figure(size(D,2)) %Abrindo uma nova figura.
u=som_umat(sMap); %Plotando a U-mat sem legendas
c=som_cplane('hexaU', sMap.topol.msize, u(:));
set(c,'edgecolor','none');

figure(size(D,2)+1) %Abrindo uma nova figura.
som_show(sMap,'umat','all'); %Plotando a U-mat com legendas

figure(size(D,2) + 2) %Abrindo uma nova figura.
som_show(sMap,'umat','all'); %Plotando a U-mat.
colormap(1-gray); %Alterando a cor do mapa.
som_recolorbar; %Alterando a cor da legenda.
```

```

%Rotulando o mapa.
som_show_add('label',sMap,'Textsize',6,'TextColor','k');

figure(size(D,2) + 3) %Abrindo uma nova figura.
som_show(sMap,'umat','all'); %Plotando a U-mat.
colormap(1-gray); %Alterando a cor do mapa.
som_recolorbar; %Alterando a cor da legenda.
h = som_hits(sMap,sDn,'crisp'); %Calculando os dados no mapa.
%Mostrando os dados sobre o mapa.
som_show_add('hit',h,'MarkerColor',[0 0 1]);
%Rotulando o mapa.
som_show_add('label',sMap,'Textsize',6,'TextColor','k');

%Criando uma estrutura de 10-cluster com agrupamento estrutural hierárquico
pela média das unidades SOM.
class=cluster(linkage(pdist(sMap.codebook),'average'),10);
% Criando o código de cores dos clusters
C=som_clustercolor(sMap, class, 'rgb2');
% Plotando o mapa
som_show(sMap,'color',C);
%Rotulando o mapa.
som_show_add('label',sMap,'Textsize',6,'TextColor','k');

%Calculando a qualidade do mapa.
bmu=som_bmus(sMap, sDn);
[qen,ten] = som_quality(sMap,sDn);

```

ANEXO A - Sumário do Datasheet do Microcontrolador ATmega328P da Atmel



ATmega48A/PA/88A/PA/168A/PA/328/P

**ATMEL 8-BIT MICROCONTROLLER WITH 4/8/16/32KB
IN-SYSTEM PROGRAMMABLE FLASH**

SUMMARY DATASHEET

Features

- High Performance, Low Power Atmel®AVR® 8-Bit Microcontroller Family
- Advanced RISC Architecture
 - 131 Powerful Instructions – Most Single Clock Cycle Execution
 - 32 x 8 General Purpose Working Registers
 - Fully Static Operation
 - Up to 20 MIPS Throughput at 20MHz
 - On-chip 2-cycle Multiplier
- High Endurance Non-volatile Memory Segments
 - 4/8/16/32KBytes of In-System Self-Programmable Flash program memory
 - 256/512/512/1KBytes EEPROM
 - 512/1K/1K/2KBytes Internal SRAM
 - Write/Erase Cycles: 10,000 Flash/100,000 EEPROM
 - Data retention: 20 years at 85°C/100 years at 25°C⁽¹⁾
 - Optional Boot Code Section with Independent Lock Bits
 - In-System Programming by On-chip Boot Program
 - True Read-While-Write Operation
 - Programming Lock for Software Security
- Atmel® QTouch® library support
 - Capacitive touch buttons, sliders and wheels
 - QTouch and QMatrix® acquisition
 - Up to 64 sense channels
- Peripheral Features
 - Two 8-bit Timer/Counters with Separate Prescaler and Compare Mode
 - One 16-bit Timer/Counter with Separate Prescaler, Compare Mode, and Capture Mode
 - Real Time Counter with Separate Oscillator
 - Six PWM Channels
 - 8-channel 10-bit ADC in TQFP and QFN/MLF package
 - Temperature Measurement
 - 6-channel 10-bit ADC in PDIP Package
 - Temperature Measurement
 - Programmable Serial USART
 - Master/Slave SPI Serial Interface
 - Byte-oriented 2-wire Serial Interface (Philips I²C compatible)
 - Programmable Watchdog Timer with Separate On-chip Oscillator
 - On-chip Analog Comparator
 - Interrupt and Wake-up on Pin Change

- Special Microcontroller Features
 - Power-on Reset and Programmable Brown-out Detection
 - Internal Calibrated Oscillator
 - External and Internal Interrupt Sources
 - Six Sleep Modes: Idle, ADC Noise Reduction, Power-save, Power-down, Standby, and Extended Standby
- I/O and Packages
 - 23 Programmable I/O Lines
 - 28-pin PDIP, 32-lead TQFP, 28-pad QFN/MLF and 32-pad QFN/MLF
- Operating Voltage:
 - 1.8 - 5.5V
- Temperature Range:
 - -40°C to 85°C
- Speed Grade:
 - 0 - 4MHz@1.8 - 5.5V, 0 - 10MHz@2.7 - 5.5V, 0 - 20MHz @ 4.5 - 5.5V
- Power Consumption at 1MHz, 1.8V, 25°C
 - Active Mode: 0.2mA
 - Power-down Mode: 0.1µA
 - Power-save Mode: 0.75µA (Including 32kHz RTC)

ANEXO B - Sumário do *Datasheet* do Acelerômetro ADXL345 da Analog Devices



3-Axis, $\pm 2\text{ g}/\pm 4\text{ g}/\pm 8\text{ g}/\pm 16\text{ g}$ Digital Accelerometer

Data Sheet

ADXL345**FEATURES**

Ultralow power: as low as 23 μA in measurement mode and 0.1 μA in standby mode at $V_S = 2.5\text{ V}$ (typical)

Power consumption scales automatically with bandwidth

User-selectable resolution

Fixed 10-bit resolution

Full resolution, where resolution increases with g range, up to 13-bit resolution at $\pm 16\text{ g}$ (maintaining 4 mg/LSB scale factor in all g ranges)

Patent pending, embedded memory management system with FIFO technology minimizes host processor load

Single tap/double tap detection

Activity/inactivity monitoring

Free-fall detection

Supply voltage range: 2.0 V to 3.6 V

I/O voltage range: 1.7 V to V_S

SPI (3- and 4-wire) and I²C digital interfaces

Flexible interrupt modes mappable to either interrupt pin

Measurement ranges selectable via serial command

Bandwidth selectable via serial command

Wide temperature range (-40°C to $+85^\circ\text{C}$)

10,000 g shock survival

Pb free/RoHS compliant

Small and thin: 3 mm $\times$ 5 mm $\times$ 1 mm LGA package

APPLICATIONS

Handsets

Medical instrumentation

Gaming and pointing devices

Industrial instrumentation

Personal navigation devices

Hard disk drive (HDD) protection

GENERAL DESCRIPTION

The ADXL345 is a small, thin, ultralow power, 3-axis accelerometer with high resolution (13-bit) measurement at up to $\pm 16\text{ g}$. Digital output data is formatted as 16-bit twos complement and is accessible through either a SPI (3- or 4-wire) or I²C digital interface.

The ADXL345 is well suited for mobile device applications. It measures the static acceleration of gravity in tilt-sensing applications, as well as dynamic acceleration resulting from motion or shock. Its high resolution (3.9 mg/LSB) enables measurement of inclination changes less than 1.0° .

Several special sensing functions are provided. Activity and inactivity sensing detect the presence or lack of motion by comparing the acceleration on any axis with user-set thresholds. Tap sensing detects single and double taps in any direction. Free-fall sensing detects if the device is falling. These functions can be mapped individually to either of two interrupt output pins.

An integrated, patent pending memory management system with a 32-level first in, first out (FIFO) buffer can be used to store data to minimize host processor activity and lower overall system power consumption.

Low power modes enable intelligent motion-based power management with threshold sensing and active acceleration measurement at extremely low power dissipation.

The ADXL345 is supplied in a small, thin, 3 mm $\times$ 5 mm $\times$ 1 mm, 14-lead, plastic package.


FUNCTIONAL BLOCK DIAGRAM

Figure 1.

Rev. D

Document Feedback

Information furnished by Analog Devices is believed to be accurate and reliable. However, no responsibility is assumed by Analog Devices for its use, nor for any infringements of patents or other rights of third parties that may result from its use. Specifications subject to change without notice. No license is granted by implication or otherwise under any patent or patent rights of Analog Devices. Trademarks and registered trademarks are the property of their respective owners.

One Technology Way, P.O. Box 9106, Norwood, MA 02062-9106, U.S.A.
Tel: 781.329.4700 ©2009–2013 Analog Devices, Inc. All rights reserved.
Technical Support www.analog.com