

UNIVERSIDADE FEDERAL DE ITAJUBÁ

Rogério Silva Rodrigues

**RECONHECIMENTO DE PADRÕES DE FALHAS
EM INTERIORES DE AERONAVES**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia de Produção como requisito parcial à obtenção do título de *Mestre em Engenharia de Produção*

Orientador: Prof. Dr. Pedro Paulo Balestrassi

Coorientador: Prof. Dr. Anderson Paulo de Paiva

Itajubá,

2009

Ficha catalográfica elaborada pela Biblioteca Mauá –
Bibliotecária Margareth Ribeiro- CRB_6/1700

R696r

Rodrigues, Rogério Silva
Reconhecimento de padrões e falhas em interiores de aeronaves /
Rogério Silva Rodrigues. -- Itajubá, (MG) : [s.n.], 2009.
72 p. : il.

Orientador: Prof. Dr. Pedro Paulo Balestrassi.
Coorientador: Prof. Dr. Anderson Paulo de Paiva.
Dissertação (Mestrado) – Universidade Federal de Itajubá.

1. Reconhecimento de padrões. 2. Redes neurais artificiais. 3.
Mineração de textos. 4. Interior de aeronaves. I. Balestrassi, Pedro
Paulo, orient. II. Paiva, Anderson Paulo de, coorient. III. Universi_
dade Federal de Itajubá. IV. Título.

UNIVERSIDADE FEDERAL DE ITAJUBÁ

Rogério Silva Rodrigues

**RECONHECIMENTO DE PADRÕES DE FALHAS
EM INTERIORES DE AERONAVES**

Dissertação aprovada por banca examinadora em 16 de dezembro de 2009, conferindo ao autor o título de *Mestre em Engenharia de Produção*

Banca Examinadora:

Prof. Dr. Pedro Paulo Balestrassi (Orientador)

Prof. Dr. Anderson Paulo de Paiva

Prof.^a Dra. Marcela Aparecida Guerreiro Machado

Itajubá,

2009

EPÍGRAFE

*“Nada sei dessa vida
Vivo sem saber
Nunca soube, nada saberei
Sigo sem saber...”*

Kid Abelha - Apneia

DEDICATÓRIA

Dedico este trabalho aos meus pais José Lázaro e Maria Aparecida por todo carinho e apoio.

AGRADECIMENTOS

Ao Professor Pedro Paulo Balestrassi por partilhar muito mais que a sua orientação durante este trabalho, mas também sua amizade;

Ao Professor Anderson Paulo de Paiva pelas sábias palavras de incentivo, contribuições e sugestões durante a coorientação sobretudo para enriquecimento deste trabalho;

À Professora Marcela Aparecida Guerreiro Machado por gentilmente aceitar o convite para avaliação deste trabalho, bem como suas sugestões de melhoria do mesmo;

Ao Professor João Batista Turrioni por incentivar meu ingresso no programa de mestrado e o início de meu despertar acadêmico;

Aos meus companheiros de mestrado e em especial meus amigos Antônio Féres e Rita Cristina por partilhar as incontáveis viagens pelas belas paisagens entre Itajubá e São José dos Campos e meu amigo Aneirson Francisco (Chiquinho) pela troca de ideias durante o desenvolvimento do mestrado e da dissertação;

À minha namorada Elisandra, por todo carinho, apoio e compreensão durante meus momentos de ausência;

Aos meus pais, por tornar a minha jornada mais amena;

Ao Eng. Renato Mamede Jr. (C&D Brasil) pelo incentivo e por acreditar neste trabalho;

A Deus por ter proporcionado força e saúde para que eu pudesse completar este trabalho.

SUMÁRIO

EPÍGRAFE.....	iv
DEDICATÓRIA.....	v
AGRADECIMENTOS.....	vi
SUMÁRIO.....	vii
RESUMO.....	ix
ABSTRACT.....	x
ÍNDICE DE FIGURAS.....	xi
ÍNDICE DE TABELAS.....	xii
1. Introdução.....	1
1.1 Considerações Iniciais.....	1
1.2 Objetivo.....	4
1.3 Justificativa.....	4
1.4 Limitações.....	11
1.5 Metodologia.....	12
2. Mineração de Dados.....	15
2.1 Introdução.....	15
2.2 Estágio Atual da Pesquisa.....	15
2.3 Contextualização ao Problema de Pesquisa.....	16
2.4 Mineração de Textos.....	18
3. Reconhecimento Neural de Padrões em Dados de Texto.....	27
3.1 Introdução.....	27
3.2 Contextualização ao Problema de Pesquisa.....	27
3.3 Redes Neurais Artificiais.....	27
3.3.1 O Cérebro Humano.....	27
3.3.2 Modelos de Neurônios Artificiais.....	29
3.3.3 Topologias de Rede.....	35
3.3.4 Tipos de Aprendizagem e Adaptação dos Pesos.....	36
3.3.5 Tipos de Redes Neurais.....	37
3.3.6 Perceptrons.....	38
3.3.7 Adaline.....	38
3.3.8 Definição da Função Erro.....	40
3.3.9 Multilayer Perceptron (MLP) e Backpropagation.....	40

3.3.10	Redes com Realimentação.....	43
3.3.11	Estabilidade e Aprendizagem	44
4.	Análise dos Resultados.....	45
4.1	Introdução.....	45
4.2	Banco de Dados.....	45
4.3	Padrões de Falhas Ocorridas no Interior de Aeronaves Regionais.....	46
4.4	Fluxo da Informação.....	49
4.5	Pré-Processamento dos Registros através de Mineração de Textos	51
4.6	Classificação Neural de Registros de Falhas.....	60
5.	Conclusão	68
5.1	Sobre o Modelo Proposto	68
5.2	Proposição para Trabalhos Futuros	69
	REFERÊNCIAS BIBLIOGRÁFICAS	70
	BIBLIOGRAFIA COMPLEMENTAR.....	72

RESUMO

No setor aeronáutico a pressão por ser mais competitivo é uma rotina. Fatores tais como tempo, preço, disponibilidade, segurança, tecnologia, qualidade, confiabilidade, gerência da informação, entre outros podem contribuir para influenciar a satisfação dos operadores de aeronaves que precisam executar uma ação de reparo dentro de um agressivo intervalo de tempo. Este estudo tem o objetivo de processar registros de falhas originados em jatos regionais comerciais utilizando técnicas de mineração do textos e redes neurais artificiais (RNA), com foco na redução do tempo gasto com a análise de um registro de falha e a respectiva disposição. As variáveis independentes são originadas durante a fase de pré-processamento (mineração de textos) do banco de dados formado pelos registros de falhas anotados no livro de bordo. Na sequência, as variáveis são aplicadas em uma rede neural para gerar a saída (disposição final), baseado nos dados históricos do banco de dados. Aproximadamente cinco anos de dados históricos foram usados para construir e validar o modelo. Espera-se que este modelo possa reduzir o tempo de disposição de um evento substancialmente e com isto facilitará a manutenção praticada pelo operador.

ABSTRACT

In the aeronautical sector the pressure of being more competitive is a routine. Factors like time, price, availability, safety, technology, quality, reliability, information management, and others can contribute to influence the satisfaction level of airlines that want to execute a repair action within aggressive time frame. This study has the objective of process the log of events from commercial regional jets using techniques of Text Mining and Artificial Neural Network (ANN), aiming to reduce the time to analyze a failure record and give the disposition. The independent variables come from a log book database, where most of the variables are originated from the pre-processing phase using text mining. Then the variables are applied in the neural network to generate the output (final disposition), based on the available historical data. Approximately five years of historical data were used to build and validate the model. Finally it is expected that the time to analyze an event can be substantially reduced, thus it will enhance the maintenance performed by the operator.

ÍNDICE DE FIGURAS

Figura 1.1 – Atrasos em Voos Domésticos no Brasil.....	7
Figura 1.2 – Atrasos em Voos Domésticos nos EUA	8
Figura 1.3 – Custo por Minuto de Atraso (US\$)	9
Figura 1.4 – Causas de Atrasos	9
Figura 1.5 – Aeronave Regional Típica – Detalhe do Interior	11
Figura 1.6 – Etapas do Trabalho.....	13
Figura 1.7 – Entradas e Saídas de um Relato de Falha.....	14
Figura 2.1 – Mineração de Textos – Exemplo.....	19
Figura 3.1 – Típico Neurônio do Cérebro Humano.....	29
Figura 3.2 – Modelo do Neurônio Artificial.....	30
Figura 3.3 – Relação entre Saída do Combinador Linear e Potencial de Ativação.....	31
Figura 3.4 – Modelo do Neurônio Artificial com Viés Aplicado.....	32
Figura 3.5 – Função Limiar (Degrau Unitário)	32
Figura 3.6 – Função Definida por Partes.....	33
Figura 3.7 – Função Sigmoid	34
Figura 3.8 – Redes com Propagação para Frente (<i>Feedforward</i>) e Realimentação	36
Figura 3.9 – Problema de classificação de eventos linearmente separáveis.....	38
Figura 3.10 – Arquitetura de uma rede formada por perceptrons multicamadas.	41
Figura 4.1 – Ciclo de Abertura e Fechamento de um Evento no Livro de Bordo.....	50
Figura 4.2 – Descritores e Frequência Absoluta nos Registros.....	57
Figura 4.3 – Participação das Respostas de Saída (Codificadas)	64

ÍNDICE DE TABELAS

Tabela 1.1 – Banco de Dados Bruto	13
Tabela 3.1 – Algumas Funções de Ativação para RNA.....	35
Tabela 4.1 – Banco de Dados	46
Tabela 4.2 – Livro de Bordo - Exemplo de Registro de Falha.....	48
Tabela 4.3 – Formas de Procura de Informação.....	53
Tabela 4.4 – Conjunto de Caracteres Válidos	54
Tabela 4.5 – Condição dos Caracteres Válidos	54
Tabela 4.6 – Lista de Sinônimos	55
Tabela 4.7 – Documentos Analisados	56
Tabela 4.8 – Descritores, Frequência, Número de Documentos e Raiz	58
Tabela 4.9 – Banco de Dados Após Mineração de Textos.....	59
Tabela 4.10 – Variáveis Após Mineração de Textos.....	60
Tabela 4.11 – Variáveis de Entrada da Rede Neural.....	62
Tabela 4.12 – Variáveis de Saída da Rede Neural	63
Tabela 4.13 – Resultados das RNAs	66

1. Introdução

1.1 Considerações Iniciais

O mercado aeronáutico do ponto de vista de quem opera uma aeronave comercial é estabelecido em um ambiente complexo onde pessoas e cargas movem-se em distâncias consideráveis ao redor do planeta.

Uma grande pressão neste cenário é percebida atualmente. Algumas razões que podem ser enumeradas neste contexto, onde a rigidez de fatores governa, são listadas a seguir:

- Horários rígidos e poucos flexíveis a serem cumpridos;
- Pressões por parte dos clientes que utilizam do transporte aéreo (seja por passageiros ou ainda no transporte de cargas);
- Tempo de alocação de suprimentos (refeições a bordo e água potável);
- Fatores externos tais como variação de preço de combustíveis devido a especulações de natureza política ou econômica do mercado internacional;
- Ferramental de manutenção, incluindo publicações técnicas que dão embasamento as práticas de manutenção;
- Problemas de escala de trabalho de tripulação, pilotos, mecânicos e funcionários.

Da outra ponta da cadeia, as empresas fornecedoras devem atentar aos sinais do mercado, buscando novas oportunidades junto aos grandes fabricantes, sendo que a concorrência para ganhar o direito de explorar um novo projeto é estritamente acirrado. Entre alguns fatores enfrentados por parte dos fornecedores, que podem significar a vitória ou a perda num processo de obtenção de um novo contrato, destacam-se:

- Diferenças mínimas durante a fase de concorrência de empresas fornecedoras perante as fabricantes das aeronaves, tais como custos diretos de manutenção (WANG, 2008);
- Promessa de índices de confiabilidade do equipamento oferecido, índices de despachabilidade (razão de voos realizados pelo número de voos programados) (BINEID, 2003; KURIEN, 1993);
- Oferta coerente de peças de reposição, baixo tempo de suporte (número de dias úteis em que o operador de uma aeronave deve esperar entre enviar uma peça ao seu devido fabricante para manutenção, modificação ou ainda recertificação), comprometimento, entre outros aspectos qualitativos subjetivamente mensuráveis (FARRERO, 2002).

Com este cenário globalizado desenhado por estas e outras inúmeras razões, as indústrias em geral não tem que se preocupar somente com um concorrente no seu estado ou mesmo país de origem, tendo então que serem competitivas numa esfera de alcance mundial.

Na indústria aeronáutica, as concorrências são acirradas, sendo que os fatores que levam a concretização de venda de uma aeronave não passam somente pelo preço, mas por toda uma sistemática e somatória de fatores complexos tais como políticos, econômicos, preços, condições de pagamento e financiamento por meio de *leasing*, suporte ao produto, facilidade de manutenção da aeronave, assistência do fabricante para com o operador da aeronave, centros de reparo localizados através do globo, facilidade ao acesso a peças de manutenção, custo envolvido com a manutenção da aeronave, entre outros.

Por sua vez os fabricantes de aeronaves normalmente não estão sozinhos em uma disputa pelo mercado, sendo que na maioria das vezes possuem parcerias de risco, onde outros fornecedores sub-contratados auxiliam no desenvolvimento técnico e também com a participação financeira. Sendo assim, o cenário de uma empresa fornecedora no âmbito aeronáutico, é às vezes até muito mais hostil do que para o próprio fabricante que é responsável por um novo projeto.

Para isso, não basta ter as melhores vantagens para a conquista de um contrato de fornecimento, como também é importante o suporte no pós-vendas, ou seja, fornecer um suporte técnico a altura do cliente e do fabricante da aeronave, com um tempo de resposta que seja a altura do mundo aeronáutico, conseqüentemente indo de encontro a interesses mútuos seja do operador ou do fabricante da aeronave.

O lado prático deste setor é que um típico operador de aeronave sempre busca a operação cada vez mais enxuta nos termos de custos. Para alcançar este objetivo, nem sempre os manuais de manutenção fornecidos pelo fabricante e seus sub-contratados são suficientes para garantir o sucesso desejado. Existe ainda a concorrência de outros segmentos tais como no Japão, onde o setor ferroviário compete em igualdade com o setor aeronáutico pelos passageiros, ou ainda países que ofertam algum tipo de incentivo ou mesmo subsídios para que um operador continue em condições de trabalho.

Tal cenário demanda, seja pelo lado do operador da aeronave, fabricante, ou fornecedor de peças para o fabricante, um uso racional de todos os recursos existentes seja na fabricação, projeto, ou ainda suporte final.

A operação de uma aeronave envolve um número complexo de pessoas, máquinas e ambientes distintos. O fabricante de uma aeronave ou ainda um fornecedor de peças podem

valer-se dos relatórios fornecidos pelos operadores das aeronaves aos respectivos fabricantes e fornecedores de peças, por exemplo os livros de bordo e relatórios do piloto e da tripulação.

Em ordem de ter uma aeronave em boas condições de aeronavegabilidade, é necessário investir uma considerável parcela de conhecimentos técnicos, recursos financeiros e ainda recursos logísticos. Estes recursos por sua vez devem ser alocados pelos operadores de aeronaves da melhor maneira possível garantindo o que se chama de gerenciamento por comprometimento (HANSSON, 2002), buscando com isso manter a aeronave segura e confiável para a realização de sua principal função, ou seja, transportar passageiros, tripulação e carga de um ponto ao outro com conforto, segurança e pontualidade.

Como parte das obrigações normais que um operador deve seguir, uma atividade que vale ser mencionada devido a sua importância é como manter a aeronave em boas condições de aeronavegabilidade. Para ajudar os operadores a utilizar a aeronave de forma coerente, os fabricantes são obrigados pelas agências reguladoras de cada país onde a aeronave será operada, de fornecer manuais que instruem os operadores como operar, manter e checar os componentes da aeronave e com isto garantir a segurança de voo.

Por sua vez os operadores também são obrigados a cumprir certas tarefas, ou seja, cada ato de manutenção deve ser devidamente registrado em banco de dados específicos para esta finalidade e reportar aos fabricantes para que os mesmos tomem conhecimento de como o produto se comporta no uso, se atende com as condições o qual fora projetado, se será necessário ações corretivas em relação ao projeto inicial, com isto fechando um ciclo de melhoria contínua. Tais relatórios que os operadores são obrigados a fornecer são geridos por agências reguladoras de cada país, sendo que tais agências fazem um esforço para que os mesmos sejam os mais parecidos de um país para o outro através de intercâmbios de informações e com isto minimizando o gasto para tratamento de informações, garantindo compatibilidade entre sistemas, entre outras.

Apesar de que um grande esforço é feito na área de coleta de dados, vários são os problemas que ocorrem no mundo real. Citando alguns problemas tais como informatização (FERNANDEZ, 2003), mecânicos não treinados que por falta de tempo ou preparo ao preencher formulários não o fazem da maneira mais adequada, erros de escrita ou ainda digitação, uso inadequado da língua inglesa, erros de classificação de peças que futuramente podem gerar uma visão equivocada de um sistema que não demandaria uma atenção especial por parte do fabricante, dificuldades de interpretação dos problemas pelas diferentes maneiras que um mecânico possa falar de uma determinada causa, envio tardio das informações por parte do operador para os fabricantes (somado ainda ao tempo necessário para interpretação e

análise e posterior solução) levando a isto a um tempo de reação muitas vezes demasiadamente longo, falta de conscientização do pessoal responsável de que tais informações são de grande importância para outras áreas correlatas (engenharia de produto, engenharia de produção, logística e comercial, controle de estoques, etc.).

O presente trabalho busca analisar uma pequena parte de toda esta complexa cadeia, limitando-se a pesquisa dos relatórios originados da operação da aeronave e as respectivas partes que apresentaram alguma anormalidade referente à sua operação, bem como as anotações feitas pelo operador da aeronave no que se diz respeito à falha que ocorreu em determinado componente, o que levou a remoção do mesmo, as percepções iniciais do mecânico, entre outras.

1.2 Objetivo

O objetivo do presente trabalho é uma análise de maneira eficaz dos dados oriundos dos livros de bordo das aeronaves, utilizando técnicas de tratamento de textos e classificação automatizadas e, conseqüentemente, gerando indicadores para inspeção e diagnóstico. Logo, é esperado que tal análise venha a proporcionar ganhos de manutenção, que por sua vez gera uma melhora na segurança, confiabilidade e disponibilidade.

1.3 Justificativa

Embora exista uma estrutura formal recomendada pela ATA iSpec 2000 (ATA, 2009) para rastreabilidade de componentes e relatório de falha de peças, alguma das informações disponibilizadas pelos operadores aos fabricantes são em sua maioria tabuladas de forma não estruturada, e com isto dificultando muito qualquer análise por auxílio de meios automatizados.

Como já mencionado os problemas comuns notados neste tipo de relatório de falhas, Luxhøj (1999) ainda enumera esforços por parte das autoridades para que tais informações sejam utilizadas de forma prática e que sejam encontradas na ocorrência de falhas, tendências cíclicas ou repetitivas que possam ajudar os inspetores a solucionar problemas de forma rápida. Em relação a taxa de falhas, trabalhos tais como o proposto por Al-Garni *et al.* (2006) mostram ainda um fértil campo de atividades, onde padrões de tendências podem ser utilizados para alertar os inspetores em um determinado operador, determinado tipo de aeronave, ou outras condições de interesse em geral. Os relatórios normalmente vêm acompanhados da discrepância observada e alguns outros dados que suportam o evento, tais como idade da aeronave, duração do voo, número de pousos e decolagens acumulados, entre outros. Tais valores podem nortear o fabricante ou até mesmo a autoridade a identificar em

um determinado operador por exemplo, até mesmo situações onde é esperado um determinado comportamento baseado no tamanho de sua frota que não esteja ocorrendo, tal como falta de envio dos relatórios em uma base regular de tempo. Em tal banco de dados é utilizado técnicas de agrupamento de dados, podendo citar modelos de redes neurais artificiais para previsões com acurácia em cada evento reportado.

De acordo com Wang *et al.* (2008), é crescente o problema de informação não estruturada nas organizações. Alguns estudos demonstraram que de 80% até 98% de todos os dados disponíveis eletronicamente nas corporações consistem de dados não estruturados ou ainda dados semi-estruturados, o que não pode ser usado em primeira mão.

Então do que adianta saber que é crescente o acúmulo de informações em todas as facetas das corporações, sendo que nestes ambientes a cultura de uma inteligência competitiva ainda não é muito visível, uma vez que a informação existe e é disponível, porém não é utilizada de forma eficiente seja por má gestão ou mesmo negligência das pessoas na alta esfera de gerenciamento?

Muitas corporações admitem que a informação é peça chave no desenvolvimento de seu negócio, mas o que fazem para utilizá-la da melhor maneira possível? Fatores, tais como mostrados a seguir, acabam por deteriorar na análise dos dados:

- Omissão ou falta de recursos alocados para pesquisas nesta área;
- Opção por contratar funcionários de baixa remuneração e com qualificação não adequada;
- Realização de tarefas de baixo valor agregado e que pouco agregam na carreira do funcionário ao invés de se investir em melhorias de um determinado processo;
- Limitação por parte da capacidade finita de um ser humano em ler e interpretar registros quando comparado a um computador com os algoritmos e ferramentas.

Mas se recentemente a informação podia ser claramente definida como um relato com começo e fim definidos, hoje é bem diferente. Consequentemente o profissional que lidar com a informação deve estar ciente de que toda a informação estratégica que o circunda, precisa ser avaliada para que relatórios possam ser gerados para a tomada de decisões. Como qualquer decisão relativa a manutenção é crucial no comportamento de uma determinada frota, fatores tais como confiabilidade, manutenibilidade e disponibilidade podem ser estudados, de acordo com Sekhon *et al.* (2005).

Shankar e Sahani (2003) também afirmam tal métrica, pois é mencionado que o aumento da disponibilidade pode ser alcançado através do refino das técnicas de manutenção e programas de manutenção preventivas. A implementação de novas técnicas pode conduzir ao aumento da disponibilidade e conseqüentemente reduzindo o tempo que a aeronave não está disponível.

Várias tentativas de sistemas de modelamento são mencionadas, tais como análise de confiabilidade e disponibilidade de uma empresa de treinamento para aeronaves, estudo e modelamento de fatores diretamente ligados ao reparo tais como tipo de maquinário empregado, idade das máquinas, arranjo e defeitos inerentes de uma peça ou determinado sistema, condições operacionais, nível de treinamento de quem executa o reparo, hábitos de trabalho, relações interpessoais, absenteísmo, medidas de segurança adotadas, condições do ambiente de trabalho, condições de infraestrutura, e outras. Devido ao grande número de variáveis, seria muito complexo analisar a relação de cada uma delas no impacto final na confiabilidade, mantabilidade e disponibilidade. Métodos modernos tal como a técnica de redes neurais artificiais e modelo de aproximação, são promissores quando aplicados neste tipo de caso, quando comparados com técnicas analíticas.

Batyrshin (2007) mostra que a necessidade de extração de informações significantes de grandes bancos de dados, pode ser útil para quem toma decisões, levando com isto ao desenvolvimento de técnicas de mineração de dados em séries de observações de eventos. O objetivo deste tipo de análise como salienta o autor é encontrar relações não suspeitas nos eventos observados e com isto resumir de maneira efetiva e de fácil entendimento para quem possui as referidas observações. Existem várias técnicas tradicionais de análise e mineração de dados, tais como segmentação, agrupamento, classificação, indexação, sumarização, detecção de anomalia, padronagem frequente, previsão baseada em dados históricos e padronagem por regras de relacionamento.

Logo, se o conhecimento precisa ser manipulado de forma eficiente por um computador, os mesmos têm que ser convertidos para uma forma estruturada e formal. Existem ainda as técnicas de processamento de linguagem natural, utilizadas já com sucesso para extrair de forma automática informação de textos não estruturados através de análise detalhada de conteúdo de um texto descritivo, que pode ser utilizado no caso das descrições dos eventos de falhas das peças das aeronaves.

Se for tomado por base a informação em termos de números, a autoridade regulamentadora brasileira (ANAC) disponibiliza em seu sítio na internet o atraso médio da frota no Brasil. No caso específico do Brasil, a determinação de atraso sofreu nos últimos

anos alterações no tempo em que é considerado atraso. Até antes de 2008, era considerado como atraso todo voo cuja aeronave decolasse 60 minutos de seu horário inicialmente agendado. A partir de Abril de 2008 a autoridade regulamentadora passou a considerar o referencial de 45 minutos como indicador de atraso de voo e em Maio de 2008 uma nova redução, para 30 minutos como sendo o indicador. Na **Figura 1.1** tem-se um panorama de como foi o desempenho dos operadores:




Figura 1.1 – Atrasos em Voos Domésticos no Brasil – Fonte: ANAC (2009)

Deste gráfico apresentado na **Figura 1.1**, pode-se tirar algumas conclusões interessantes tais como sazonalidade de atrasos (verifica-se picos em períodos referentes de *alta temporada* tais como os meses de julho e dezembro). É interessante observar o amadurecimento do setor no Brasil, pois a curva mantém uma tendência de queda mesmo com metas mais rígidas para o valor referencia para atraso. A ANAC já estuda inclusive a adoção do referencial de atraso alinhado com o valor de referencia internacional (15 minutos).

O mesmo é observado em outros países do mundo. Nos Estados Unidos, país onde existe o maior mercado de voos domésticos, os valores ainda são mais agressivos. O valor de referencial de atraso é de 15 minutos. A primeira vista os números podem divergir se comparados com a **Figura 1.1**, porém, é importante salientar que nos Estados Unidos o referencial para atraso é menor que no Brasil, logo a comparação não é válida em primeira instância.

A **Figura 1.2** mostra os atrasos de voos nos Estados Unidos:




Figura 1.2 – Atrasos em Voos Domésticos nos EUA – Fonte: BTS (2009)

É interessante observar na **Figura 1.2** algumas similaridades quanto a forma da curva, demonstrando os efeitos de sazonalidades (também períodos de declínio acompanhados de períodos de pico quando dos meses de *alta temporada*).

O fato é que não importa o mercado analisado, é de suma importância olhar tal indicador, o impacto do mesmo em diversos segmentos da sociedade, bem como a necessidade de otimização de processos existentes para a melhoria gradativa dos mesmos. Então justifica-se a otimização do estudo das falhas como um meio de se alcançar melhora no desempenho dos operadores. Além do problema junto a autoridade regulamentadora, cada minuto de atraso gera todo um custo para o operador em sua cadeia de trabalho. Um estudo publicado por Knotts (1999) a cerca de dez anos atrás mostra que em alguns casos os custos recorrentes por atrasos em voos agendados podem chegar a cifras de US\$ 775,00 por minuto em valores atualizados. Entre a diversidade encontrada nas operações de uma aeronave, pode-se citar as dificuldades de acomodação de bagagens e cargas no compartimento de carga, suprir a aeronave com refeições nas *galleys* para serem posteriormente servidas durante o voo, problemas com escalas da tripulação, limpeza e abastecimento de água potável bem como remoção de detritos, tempo para embarque de passageiros, entre outros. Tais demandas como as mencionadas anteriormente levam a perdas como descrito por Kumar (1999). A **Figura 1.3** mostra o custo de atrasos por minuto para alguns modelos de aeronaves, que apesar de não serem aeronaves regionais, servem de base para reflexão:




Figura 1.3 – Custo por Minuto de Atraso (US\$) – Fonte: Adaptado de Knotts (1999)

Embora que grandes progressos foram feitos, os números demonstrados pela IATA (International Air Transport Association) no triênio de 1990-1992 as perdas por atraso foram na ordem de US\$ 11,5 bilhões enquanto que dados mais recentes de 2007 mostraram perdas na ordem de US\$ 8,1 bilhões. Em termos de minutos, isto se refere a soma de 134 milhões de minutos a uma taxa de US\$ 60 por minuto.

Dentre a variedade de registros gerados, um estudo feito por Knotts (1999) mostra os principais motivos por atraso. Estes motivos são quantificados conforme gráfico da **Figura 1.4**:




Figura 1.4 – Causas de Atrasos – Fonte: Adaptado de Knotts (1999)

Além do segmento de manutenção de operação, as operações são baseadas em outras três disciplinas (SARAC, 2000):

- planejamento de horários de voo;

- designação de frota;
- gerenciamento de lucros.

Conseqüentemente os registros a serem analisados nos livros de bordo decorrentes de “atrasos por falhas técnicas” representam cerca de 20% das causas, que se fosse extrapolado numa hipótese em cifras como as apresentadas anteriormente, dos US\$ 8,1 bilhões acumulados em perdas de atraso em 2007, seria algo aproximadamente em torno de US\$ 1,62 bilhões.

Após esta breve análise do contexto em que se encontra os atrasos gerados pelos operadores, bem como as cifras envolvidas e a relevância de um estudo neste sentido em se diminuir as perdas geradas, é interessante lembrar que o estudo deste trabalho foca justamente nos atrasos por falhas técnicas encontradas nos livros de bordo das aeronaves.

Mesmo que o operador por muitas vezes irá se resguardar em estoques de segurança para que possa resolver prontamente problemas oriundos de peças que falharam e fazer a troca das mesmas, para depois reparar, em vista do cenário atual onde se busca redução de custos bem como redução de estoques, é interessante que a peça que venha apresentar defeito possa ser reparada no menor tempo possível. A seguir será mostrado como é formado o banco de dados bem como o universo de reparos.

Todas estas tarefas podem ser mutuamente relacionadas, por exemplo, a tarefa de segmentação pode ser perfeitamente utilizada para indexação, agrupamento, sumarização, etc. Uma vez que a complexidade de um sistema aumenta, a habilidade em fazer uma decisão precisa e significativa diminui até que um problema seja grande o suficiente para que a relevância do mesmo possa ser perceptível. O mesmo pode ser dito em relação a um banco de dados onde parte dos dados relevantes está imerso em uma nuvem de campos de texto. Dificilmente a percepção humana será capaz de identificar problemas relevantes até que os mesmos tenham alguma significância frente aos outros.

Como toda a análise de dados deste trabalho será focada em relatórios (documentos que contém as informações referentes às falhas reportadas), espera-se ainda que o uso de técnicas de mineração de textos (*text mining*) na codificação dos eventos somado ao posterior uso de técnicas de redes neurais artificiais, mostrem-se eficazes no âmbito de extração de informações úteis para o negócio de uma corporação, originadas de uma massa de dados não estruturados.

Então, como o ambiente do setor aeronáutico é extremamente competitivo e cada minuto perdido afeta diretamente o operador e quem depende da aeronave, justifica-se o

objetivo do presente trabalho em estudar as falhas oriundas dos livros de bordo como maneira de alcançar uma possível melhora de operação das aeronaves.

1.4 Limitações

O presente trabalho irá tratar os relatórios originados de falhas reportadas em peças de aeronaves regionais. Tais registros podem ser gerados pela tripulação da aeronave em qualquer etapa do voo, porém, serão atacados pelos mecânicos somente com a aeronave em solo. Uma falha por sua vez pode afetar o tempo de despacho da aeronave para o próximo voo, ou ainda no mesmo instante de um determinado voo, caso a aeronave apresente-se nas condições de deixar o aeroporto, por exemplo se a mesma já estiver com todos os passageiros a bordo aguardando para deixar a área de embarque e tomar a pista rumo a decolagem. Logo, é evidente que o universo de pesquisa entre os registros gerados é muito amplo e ainda por facilidade de acesso aos dados, o trabalho limita-se a analisar apenas componentes do interior de aeronaves regionais. Em termos do universo de *part numbers* (número utilizado para descrever uma determinada peça) analisados, estima-se que aproximadamente 30% dos *part numbers* estão inclusos no presente trabalho e uma monta da ordem de aproximadamente 1,5 milhão de dólares (para atender a demanda de uma frota padrão de seis aeronaves regionais).




Figura 1.5 – Aeronave Regional Típica – Detalhe do Interior

Através da **Figura 1.5** é possível identificar alguns dos vários componentes que formam o interior de uma típica aeronave do porte regional, conforme a lista a seguir:

- Assentos para passageiros, observador e tripulação (comissários de bordo). Assentos de piloto e co-piloto são considerados itens do *cockpit*;
- Bagageiros suspensos para armazenamento de bagagens de mão;

- Armários para armazenamento de equipamentos de emergência tais como estojo de primeiros socorros, botes infláveis, colete salva-vidas, extintores de incêndio portáteis, entre outros. Ainda nestes armários existe ganchos para pendurar casacos e espaço para armazenagem de bagagem de mão dos tripulantes;
- Partes estruturais como divisória entre cabine do piloto e cabine de passageiros, divisória entre primeira classe, executiva e econômica;
- Revestimentos laterais entre fuselagem e cabine, bem como moldura para as janelas e portas (sejam elas portas de emergência, serviço ou de passageiros);
- Cozinhas (*Galleys*) para preparo de alimento e armazenamento de bebidas pelos comissários de bordo;
- Lavatórios com sanitário, pia, espelho e mesa para troca e limpeza de bebês;
- Sistema de iluminação (luzes de leitura, emergência, fotoluminescentes, marcação de saídas, cortesia, etc.);
- Sistemas de detecção de fumaça e extinção de incêndios (para prevenção e extinção de incêndio seja no compartimento de carga ou nos lavatórios) e de fornecimento de oxigênio em situações de emergência (no caso de descompressão súbita da cabine);
- Painéis de piso da cabine e compartimento de carga.

1.5 Metodologia

Os dados analisados neste trabalho compreendem uma coletânea de vários operadores de aeronaves regionais ao redor do mundo, que fazem uso da língua inglesa para compilação dos mesmos. Através de uma modelagem e simulação, o trabalho tem como objetivo coletar e utilizar os dados provenientes de falhas registradas nos livros de bordo da aeronave.

Will *et al.* (2002) mostram que embora a pesquisa normativa empírica não se preocupe com geração do conhecimento científico, a própria carência de publicações na área é um espaço para gerar melhoria de processos já existentes, ou seja, na forma de como se trata as falhas registradas no livro de bordo da aeronave e ainda o conhecimento adquirido do uso de técnicas já sedimentadas na literatura em ambientes onde as mesmas eram marginalizadas.

Esta pesquisa basicamente consiste em aproveitar as técnicas existentes de mineração de textos e redes neurais para modelagem e simulação de um sistema capaz de prever respostas futuras baseadas em eventos já acontecidos, originados de registros de vários livros de bordo da aeronave, coletados entre os anos de 2004 e 2008. Embora na literatura encontrem-se trabalhos, seja na área de mineração de textos bem como de redes neurais com

aplicações práticas no setor aeronáutico, poucos são os trabalhos publicados onde se emprega simultaneamente estas duas técnicas.



Figura 1.6 – Etapas do Trabalho

A **Figura 1.6** mostra de forma sucinta a abordagem do trabalho. Por sua vez, tais etapas são resumidamente compostas de:

1) Coleta de dados brutos dos relatórios dos pilotos (*Pilot Reports* ou PIREPs), onde estes dados são tabulados na forma de um banco de dados, onde cada variável da tabela está respectivamente associada com um dado de um determinado registro, conforme mostrado na

Tabela 1.1:

Variáveis	Descrição
1-2	Ano e Mês do Registro
3-4	Problema e Ação Reportado
5	Capítulo ATA da peça
6	Sub-Capítulo ATA da peça
7	Houve interrupção? (sim/não)
8	Tipo de Interrupção: <ul style="list-style-type: none"> • atraso (<i>delay</i>) • cancelamento (<i>cancellation</i>) • retorno da pista de decolagem (<i>return from runway</i>)
9	Concordância do fabricante em relação à falha reportada
10	Comentário do fabricante em relação à falha reportada

Tabela 1.1 – Banco de Dados Bruto

2) Pré-processamento de cada registro utilizando Mineração de Textos.

- a) Coleta, compilação e tratamento do banco de dados;
- b) Contagem de frequência das palavras e relevância das mesmas;
- c) Eliminação de registros duplicados, vazios e palavras não relevantes;
- d) Eliminação de ruídos (uso de filtros para descartar erros de grafia);
- e) Geração de uma tabela de descritores dos documentos (*keywords*).

3) Uso dos descritores dos documentos (*keywords*) em conjunto com as outras variáveis qualitativas relevantes ao processo conforme mostradas na **Tabela 1.1**, definindo

uma tabela com as variáveis de entradas (X_n) bem como as respectivas saídas (Y_n) para preparação do modelamento da Rede Neural Artificial (RNA);

4) Uso do resultado dos itens (1), (2), e (3) de forma que possa ser feito o reconhecimento de padrões de texto e que estes possam ser usados para treinamento, teste, e validação de uma RNA de classificação. Com isto tal RNA poderá prever respostas futuras baseadas nas entradas apresentadas ao sistema (entradas da RNA – X_n), disponibilizando uma resposta ao mecânico de forma a facilitar seu trabalho de pesquisa de pane.

De forma resumida, a **Figura 1.7** mostra como seria o processo de entrada e saída do sistema a ser modelado no presente trabalho, sendo que as entradas serão compostas pela tabela originada no pré-processamento através da mineração de textos dos respectivos registros encontrados na documentação fornecida através dos PIREPs e livros de bordo e ainda outras variáveis qualitativas, enquanto a saída será a disposição final para o evento (que após a modelagem será apontado através da RNA treinada específica para este propósito).

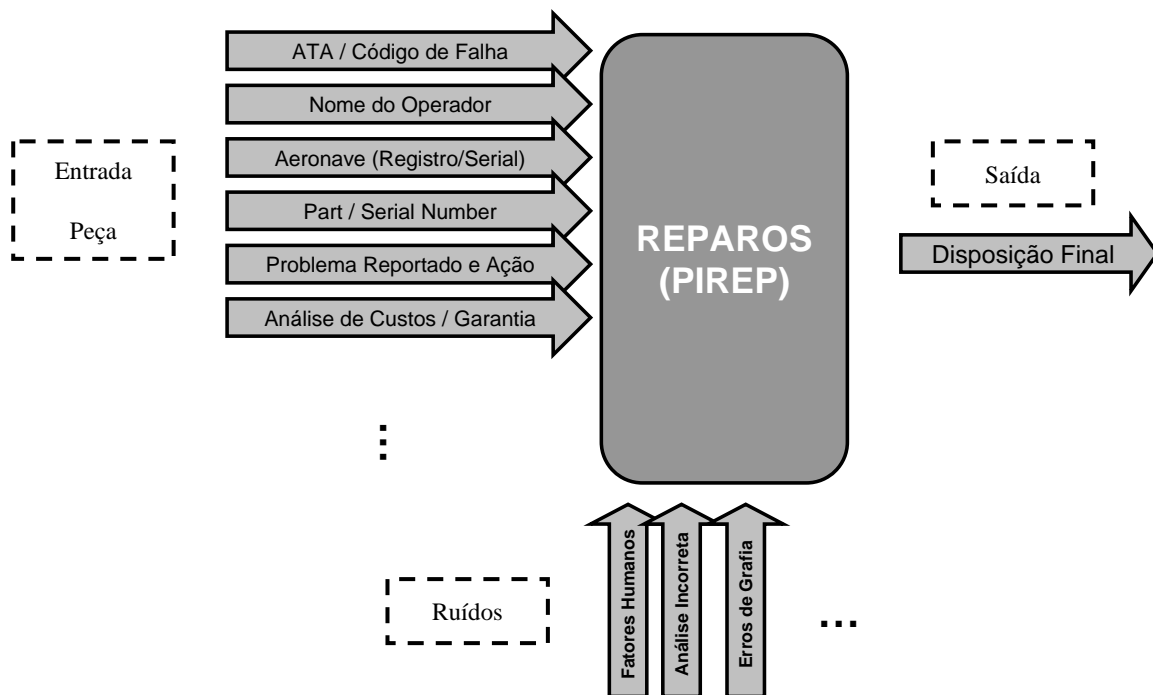


Figura 1.7 – Entradas e Saídas de um Relato de Falha

A seguir, no **Capítulo 2** será discutido a técnica de Mineração de Textos que será empregada neste trabalho.

2. Mineração de Dados

2.1 Introdução

A mineração de dados consiste em analisar um banco de dados qualquer formado por observações de um determinado ambiente e armazenadas das mais variadas formas (*e-mails*, tabelas, fichas de ocorrências, livros de bordo, etc.) e na busca de relações que possam estar contidas entre as variáveis que descrevem o evento, para que seja possível com isto o resumo e modelagem do objeto de estudo.

A Mineração de Dados pode ser descrita resumidamente como a busca por informações implícitas em um banco de dados e que seria demasiadamente difícil para um ser humano descobrir, seja pelo tempo necessário para pesquisa ou ainda pelo tamanho do banco de dados a ser analisado. Tais técnicas lidam tanto com valores quantitativos quanto qualitativos e é aplicada com sucesso em diversos segmentos e áreas tais como análise de risco de crédito, pesquisas de opinião, inteligência em padrões de compras de determinados clientes, fichas cadastrais, entre outros. Em particular e do interesse deste trabalho, será descrita a técnica de Mineração de Textos (que é uma particularidade da Mineração de Dados – porém aplicada em textos descritivos e não estruturados), que será utilizada como base de um pré-processamento dos registros do banco de dados que será utilizado na modelagem do problema em estudo. Para isto será escolhido quais características de cada técnica melhor se aplicam ao problema.

2.2 Estágio Atual da Pesquisa

A pesquisa basicamente consiste em aproveitar as técnicas existentes de mineração de textos e redes neurais para modelagem e simulação de um sistema capaz de prever respostas futuras baseadas em eventos já acontecidos, originados de registros dos livros de bordo da aeronave. Embora na literatura existam vários trabalhos seja na área de mineração de textos ou na área de redes neurais, poucos são os trabalhos publicados no setor aeronáutico onde se emprega simultaneamente estas duas técnicas.

Para a mineração de textos será empregado um pequeno dicionário de termos comuns do jargão aeronáutico como forma de otimização dos descritores encontrados, pois sem isto os resultados iniciais não seriam satisfatórios, uma vez que devido ao tempo curto para se realizar a anotação de um evento no livro de bordo, vários são os acrônimos utilizados ou pela tripulação ou pelos mecânicos. Ainda os vetores de textos *numerizados* serão normalizados

para que não se tenha problema de um registro que use mais ou menos palavras em relação à um outro qualquer.

2.3 Contextualização ao Problema de Pesquisa

De acordo com Cheung (2008), é crescente o problema de armazenagem de informações nas corporações através de formas não estruturadas de banco de dados. Tal estudo revelou que de 80% a 98% de todos os dados disponíveis nas corporações consistem em dados não estruturados, ou seja, os dados não são facilmente recuperados por meios de primeira mão. Para que os dados possam ser manipulados e utilizados de forma precisa é necessário que eles sejam convertidos em um arranjo estrutural. Por exemplo, de nada adianta para um sistema de pesquisa estrutural que uma informação esteja disponível na forma de emails, documentos em diferentes formatos proprietários tais como PDF (Portable Document Format – Adobe Acrobat), planilhas em Microsoft Excel, documentos escritos a mão e posteriormente escaneados com uso de digitalizadores de imagem (*scanner*) para formatos de arquivos gráficos por falta de tempo de serem digitados, entre outros.

Neste estudo os dados a serem manipulados também não diferem do que foi descrito acima. Muitas vezes por parte de falta de padronização entre diferentes operadores, os dados são fornecidos de várias maneiras. Então é preciso que eles sejam compilados e agrupados de uma forma única para que técnicas de análise possam então ser aplicadas para o auxílio na tomada de decisões.

Leiner (2008) ainda cita que o uso dos avanços nas técnicas de mineração de texto e ainda da experiência humana, é possível que tal metodologia seja usada para converter textos livres e não estruturados tal como o objeto de estudo deste trabalho que consiste no relato do tripulante da aeronave que escreveu e reportou um problema e ainda a ação tomada pelo mecânico em um arranjo estrutural para que possa ser manipulado facilmente por programas computacionais de mineração de textos.

Wu *et al.* (2004) mostram que sistemas especializados já não são uma novidade no setor aeronáutico, que busca justamente a extração de informações de falha para montar um sistema de diagnóstico das mesmas.

Alguns problemas podem aparecer quando da tentativa de extração de informações que são oriundas de linguagem natural, tais como escrita incorreta, dualidade de significados de uma mesma palavra (imagine por exemplo a palavra *table* que dependendo do contexto aplicado pode significar tanto “tabela” como “mesa”), relatórios preenchidos erroneamente ou ainda com falta de clareza de descrição do problema (estes que seriam facilmente

decodificados por pessoas com certo nível de experiência no setor, porém mais *difíceis* para um computador), entre outros.

Wang *et al.* (2008) mostram alguns destes e outros problemas quando se utiliza programas de processamento de textos, bem como técnicas utilizadas para lidar com a linguagem natural chamada de Processamento de Linguagem Natural (PLN). Tais técnicas foram utilizadas com sucesso para extração automática e útil de textos não estruturados, utilizando uma análise detalhada de conteúdo dos textos descritivos. De uma forma análoga, espera-se que tais técnicas de mineração de textos possam ser utilizadas com sucesso no presente trabalho para o pré-processamento dos registros do banco de dados.

Embora os dados não estruturados possam ser convertidos em dados estruturados, imagine que seria uma tarefa demasiadamente enfadonha para um indivíduo percorrer e analisar registro por registro. Existe ainda a possibilidade de que exista relacionamento entre os registros, que pode estar *oculto* no texto e por sua vez poderia passar despercebida em uma primeira análise. Como situações ocultas podemos exemplificar por uma determinada peça que apresenta registros de problemas em um determinado operador, porém em outros a mesma comporta-se normalmente. Para um analista criterioso, ao se deparar com registros, algumas perguntas poderiam ser feitas tais como:

- Existe a possibilidade de falta de treinamento da tripulação ou mesmo dos mecânicos no operador analisado?
- Este problema tem relação a alguma sazonalidade (por exemplo: operação em condições extremas de temperatura como inverno rigoroso, uso fora dos padrões normais tais como alta temporada de férias, entre outros)?
- As instruções fornecidas aos operadores tais como procedimentos de manutenção, procedimentos de teste, pesquisa e isolamento de panes, etc. estão adequados?
- Quais contribuições a análise dos registros de falhas podem trazer para o desempenho da frota e em quais aspectos (satisfação do operador, redução dos custos de manutenção, melhora das técnicas de manutenção, etc.)?

Finalmente na sequência de perguntas, de nada adiantaria apenas a vetorização dos registros através da uso da mineração de textos, porém como classificar este novo banco de dados vetorizado? É o que será abordado no **Capítulo 3**.

2.4 Mineração de Textos

De acordo com Chiang (2008), vários são os problemas para extrair informações relevantes em um texto. Os problemas são desde simples tarefas de categorização até a extração de palavras chave (*keywords*) de um texto. A técnica de mineração de textos consiste em representar um determinado documento como sendo uma “*caixa de palavras*”, ou seja, um documento D qualquer pode ser convertido em um vetor de palavras, onde cada palavra receberá um determinado valor de frequência f e um peso w . Logo o documento D pode ser escrito da seguinte forma:

$$D = [(f_1, w_1), (f_2, w_2), (f_3, w_3) \dots (f_n, w_n)] \quad (2.1)$$

Prado e Ferneda (2008) exemplificam o uso das técnicas de mineração de textos, onde todas as palavras encontradas nos registros em análise são enumeradas e contadas com o objetivo de se criar uma tabela de documentos e a respectiva contagem de palavras dos mesmos, ou seja, uma matriz de frequência que enumera o número de vezes que cada palavra ocorre em cada documento.

Tal notação já é bem conhecida para documentos, que são representados em um espaço multidimensional por vetores. Logo o vetor que representa um documento é formado pela seleção de palavras únicas e contando o número de ocorrência das palavras. Então a frequência das palavras é também armazenada de uma forma vetorial, que estará relacionada com o respectivo documento que a originou. É fácil perceber que do ponto de vista computacional será bem mais fácil o processamento dos dados desta forma do que da forma anterior quando o texto encontrava-se de forma não estruturada. Por sua vez, a forma de *contagem* das palavras que será armazenada na tabela pode ser feita de diversas maneiras.

De forma didática, poderia ilustrar os documentos analisados como entradas do sistema de mineração de textos e as respectivas saídas como as frequências das palavras em questão. A **Figura 2.1** mostra de uma forma clara como é feita tal transformação:

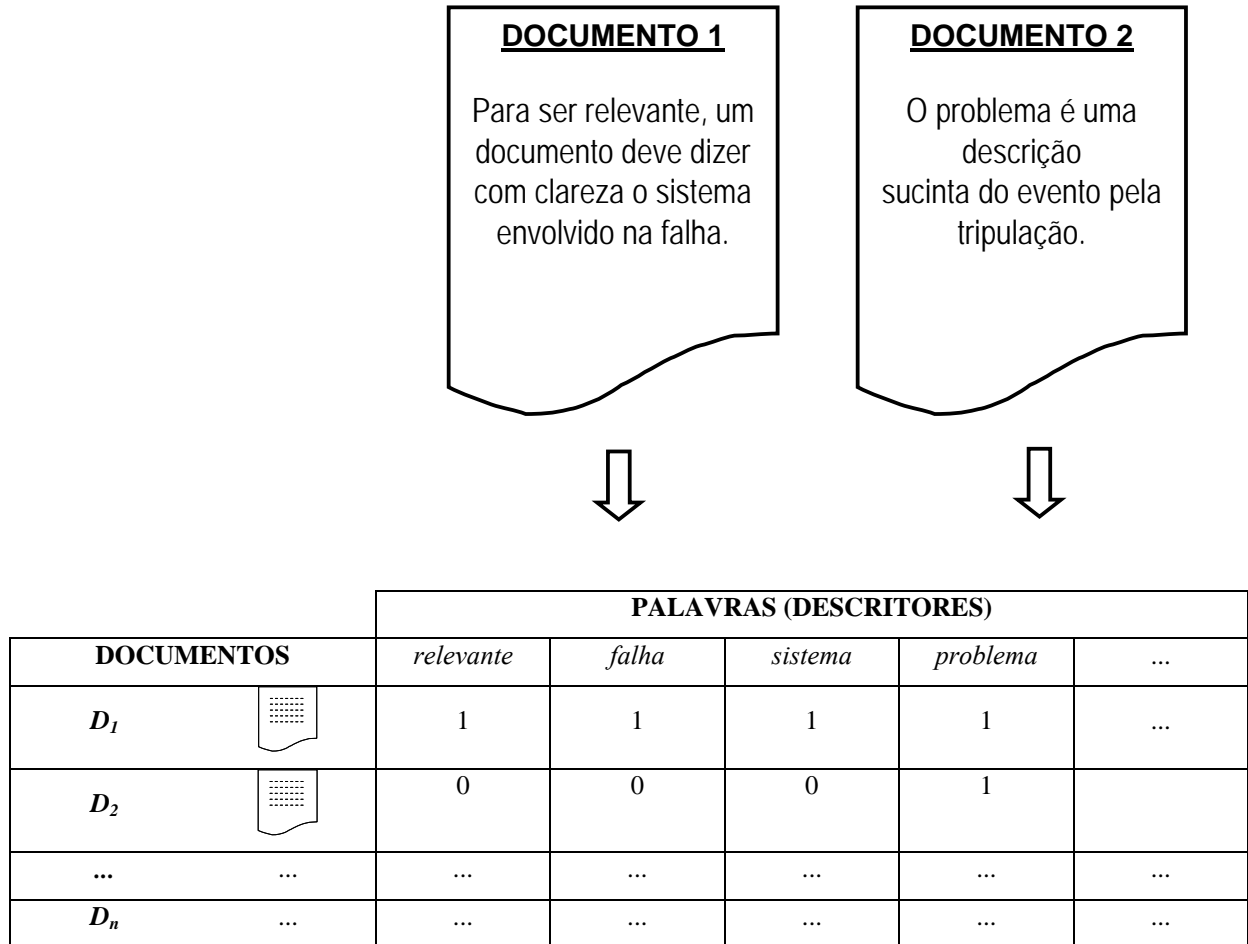


Figura 2.1 – Mineração de Textos – Exemplo

Como pode ser observado, na primeira linha tem-se a contagem de palavras para o documento 1, onde foram contadas as palavras *relevante*, *falha*, *sistema* e *problema*. Para cada uma das palavras, a matriz de documentos e palavras construída, mostra a simples ocorrência das palavras, ou ainda a contagem simples das mesmas por número de aparições nos documentos.

O mesmo ocorre para o documento 2, este porém mostra somente a palavra *problema* com contagem igual a uma unidade. As técnicas de mineração de textos funcionam melhor em um ambiente de um grande número de documentos com poucas palavras ao invés de um pequeno número de documentos com muitas palavras. Isto se deve pois análises estatísticas neste caso são fracas uma vez que a população de documentos é pequena, no que diz respeito a extração de conceitos (por exemplo extrair conceitos de um livro de 200 páginas com centenas de palavras ao invés de extrair conceito de um relatório de falha de apenas 1 página porém com um número reduzido de palavras – algo em torno de 50 palavras). Quanto ao peso das palavras, várias estratégias também podem ser utilizadas, assim como foi ilustrado na *Figura 2.1*.

Dentre os métodos existentes para contagem de frequência de palavras (wf), destacam-se:

- **Frequência Binária:** A frequência binária é a transformação mais simples que pode ser feita para enumerar se uma palavra é presente ou não em um determinado documento. A matriz de documentos resultantes será então formada somente pelos algarismos 0 (ausência) ou 1 (presença) das palavras analisadas. Escrevendo na forma matemática tem-se:

$$f(wf) = 1 \quad \text{para } wf > 0 \quad (2.2)$$

- **Frequência Linear:** A frequência linear é a transformação onde é enumerado a quantidade absoluta das palavras presentes em um determinado documento. A matriz de documentos resultantes da contagem de palavras será então formada pela quantidade de palavras em cada documento, que reflete diretamente o quanto uma determinada palavra é importante ou saliente em cada documento, porém não relacionando com outros documentos. Então a frequência linear não leva em conta o problema se uma palavra aparece um grande número de vezes em um determinado documento, porém não aparece no restante dos documentos. Escrevendo na forma matemática tem-se:

$$f(wf) = n \quad \text{com } n \geq 0 \quad (2.3)$$

onde n é o número de palavras

- **Frequência Log:** A frequência Log envolve uma transformação onde a matriz de documentos resultantes da contagem de palavras é formada pela contagem absoluta de palavras em um único documento, porém relacionando cada palavra de um determinado documento juntamente com o peso que determinada palavra tem sobre todo o conjunto de documentos analisado. Desta maneira, imagine o exemplo onde uma palavra apareça uma única vez em um documento D_1 , mas três vezes em um documento D_2 . Então não se pode concluir que a mesma palavra chave seria mais importante no cenário do documento D_2 para descrevê-lo e não ser um descritor do documento D_1 somente pelo fato da mesma ter aparecido uma única vez neste. Logo é com este cenário que a transformação Log se encaixa, resolvendo com isto o problema de computar este tipo de situação:

$$f(wf) = 1 + \log(wf) \quad \text{para } wf > 0 \quad (2.4)$$

- **Frequência de Documentos Inversa (*Inverse Document Frequency* ou *idf*):** A frequência de documentos inversa (*idf*) é utilizada quando a análise quer refletir mais cuidadosamente a frequência relativa de documentos para diferentes palavras. Por

exemplo, o termo “passageiro” pode ocorrer frequentemente em todos os documentos em uma determinada análise, enquanto outro termo como “divisória” pode ocorrer apenas em alguns. A razão pela qual isto pode acontecer é que o termo “passageiro” pode estar em vários contextos diferentes, não importando se faz parte de um tópico específico como no caso de “divisória”, que semanticamente é um termo focado e provavelmente será encontrado nos documentos (registros) que fazem referência a divisória de cabine de passageiro e área da tripulação. Logo esta transformada de frequência inversa de documentos reflete tanto a singularidade e especialidade das palavras em termos da frequência de documentos, como também a frequência da ocorrência das palavras. Então a *idf* reúne as particularidades da frequência Log como também inclui o peso que avalia para zero se uma palavra ocorre em todos os documentos ($\log N/N = \log 1 = 0$) ou para o valor máximo caso a palavra seja encontrada em apenas um único documento ($\log N/1 = \log N$). De uma maneira matemática, tem-se para cada palavra *i* e para cada documento *j*:

$$idf(i, j) = \begin{cases} 0 & \text{se } wf_{ij} = 0 \\ (1 + \log(wf_{ij})) \log \frac{N}{df_i} & \text{se } wf_{ij} = 1 \end{cases} \quad (2.5)$$

Além do uso das frequências para caracterização das palavras, outros artifícios são empregados para construção da matriz de números. Uma vez que o número de diferentes palavras que formam uma coleção de documentos pode ser muito grande e ainda conter um número considerável de palavras irrelevantes para a construção de uma tabela de palavras chave, ainda é necessário separar tais “gorduras” para que possa ser poupado recursos computacionais e conseqüentemente o resultado final venha agregar informação útil e passível de compreensão. Um bom exemplo de palavras que não agregam valor seriam artigos e preposições. Através de dicionários é possível excluir tais palavras, sendo esta uma etapa antes de se partir para a mineração de textos propriamente dita. Então através de um processo básico é feita a exclusão de tais palavras que não agregam valor. Tais palavras são denominadas de *stop words* (por exemplo: artigos “o, a, os, as”). Existe ainda a possibilidade do agrupamento de palavras semelhantes (antes e depois da análise) por dicionários de sinônimos, buscando assim a raiz de significado de cada palavra. Esta técnica de agrupamento de palavras semelhantes é chamada de *stemming*. Por exemplo, imagine o verbo na forma infinitiva *to break* (que significa quebrar). Este verbo pode aparecer nos registros de diversas

formas tais como pessoas, tempos (presente, passado, ou particípio). De uma maneira análoga, tais diferenças são todas escritas de uma forma comum, para facilitar o processo de análise, então *break*, *broke* ou *broken* são *traduzidos* para por exemplo *break*.

Ainda existe a técnica de Decomposição de Valores Singulares (DVS). Com isto é possível o agrupamento de formas diferentes de se escrever um determinado evento, tal como um exemplo típico do *sistema confiável* ou o *sistema sem defeitos* (*um sistema sem defeitos é um sistema confiável!*).

Brzezinski (2000) também menciona que este é um típico problema do uso do grande número de palavras e sua semântica. Existe o problema de ambiguidade natural na linguagem que pode não ser preservado por um esquema de representação vetorial do texto, tal como mostrado no exemplo anterior. Logo com o uso da DVS a mineração de textos fica muito mais robusta do que se fosse somente utilizado a contagem pura e simples de palavras.

Em vias gerais a DVS consiste em reduzir a dimensionalidade total da matriz de entrada (número de documentos incluídos em relação ao número de palavras extraídas) para um espaço dimensional reduzido, onde cada dimensão consecutiva representa o maior grau de variabilidade (entre palavras e documentos) possível.

Larose (2006) mostra que tal técnica é bastante similar a Análise de Componentes Principais (PCA), onde o propósito é explicar a correlação estrutural de um conjunto de variáveis utilizadas para prever e modelar algum evento, porém valendo-se de uma combinação linear das mesmas. A variabilidade total de um conjunto de dados produzida pelo conjunto completo de m variáveis pode ser contabilizada contudo com um conjunto menor de k variáveis originadas da combinação linear das mesmas, ou seja, este conjunto reduzido de k variáveis contém tanta informação quanto o conjunto original de m variáveis. Logo se desejado, é possível que o conjunto original de m variáveis possa ser trocado pelo conjunto k de variáveis (com $k < m$) porém sem perder as informações originais.

Assim sendo, pode-se imaginar que o conjunto original de registros formado pelas m variáveis (X_1, X_2, \dots, X_m) formam um sistema de coordenadas em um espaço de m dimensões. Os componentes principais representam um novo sistema de coordenadas, encontrado pelo rotacionamento do sistema original cujas direções apontem a máxima variabilidade. Quando o sistema for preparado para a redução de dimensão e conseqüentemente a redução de dados, a análise deve preocupar-se primeiro em colocar os dados de uma forma normalizada, de forma que a média para cada variável seja zero e o desvio padrão seja igual a um. Então cada variável X_i representa um vetor $n \times 1$, onde n é o número de registros. Logo a representação da variável normalizada como sendo o vetor $n \times 1$ (n linhas por *uma* coluna) Z_i , onde

$Z_i = (X_i - \mu_i)/\sigma_i$ sendo μ_i a média de X_i e σ_i é o desvio padrão de X_i . De uma forma mais clara, numa notação matricial esta normalização pode ser escrita como sendo $Z = (V^{1/2})^{-1}(X - \mu)$, onde o expoente “-1” refere-se à matriz inversa e o $V^{1/2}$ é a diagonal da matriz (cujas entradas diferentes de zero estão somente na diagonal) conforme matriz a seguir:

$$V^{1/2} = \begin{bmatrix} \sigma_1 & 0 & \cdots & 0 \\ 0 & \sigma_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \sigma_p \end{bmatrix} \quad (2.6)$$

De maneira similar, a matriz de covariância simétrica pode ser escrita como:

$$\Sigma = \begin{bmatrix} \sigma_1^2 & \sigma_{12}^2 & \cdots & \sigma_{1m}^2 \\ \sigma_{12}^2 & \sigma_2^2 & \cdots & \sigma_{2m}^2 \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{1m}^2 & \sigma_{2m}^2 & \cdots & \sigma_m^2 \end{bmatrix} \quad (2.7)$$

onde σ_{ij}^2 , $i \neq j$ refere-se à *covariância* entre X_i e X_j :

$$\sigma_{ij}^2 = \frac{\sum_{k=1}^n (x_{ki} - \mu_i)(x_{kj} - \mu_j)}{n} \quad (2.8)$$

A covariância é a medida do grau de variabilidade entre duas variáveis. Uma covariância positiva indica que quando uma variável aumenta, a outra tende a aumentar também. O mesmo acontece em uma covariância negativa, que indica que quando uma variável aumenta, a outra por sua vez tende a diminuir. A notação σ_{ij}^2 é usada para mostrar a variância de X_i . Se X_i e X_j são independentes, $\sigma_{ij}^2 = 0$, mas $\sigma_{ij}^2 = 0$ não implica que X_i e X_j são independentes. Note que a medida da covariância não é escalonada, então a mudança das unidades de medida deve mudar o valor da covariância.

O *coeficiente de correlação* r_{ij} evita a dificuldade pelo escalonamento da covariância por cada um dos desvios padrão:

$$r_{ij} = \frac{\sigma_{ij}^2}{\sigma_{ii}\sigma_{jj}} \quad (2.9)$$

A matriz de correlação pode ser escrita da seguinte maneira:

$$\rho = \begin{bmatrix} \frac{\sigma_{11}^2}{\sigma_{11}\sigma_{11}} & \frac{\sigma_{12}^2}{\sigma_{11}\sigma_{22}} & \dots & \frac{\sigma_{1m}^2}{\sigma_{11}\sigma_{mm}} \\ \frac{\sigma_{12}^2}{\sigma_{11}\sigma_{22}} & \frac{\sigma_{22}^2}{\sigma_{22}\sigma_{22}} & \dots & \frac{\sigma_{2m}^2}{\sigma_{22}\sigma_{mm}} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\sigma_{1m}^2}{\sigma_{11}\sigma_{mm}} & \frac{\sigma_{2m}^2}{\sigma_{22}\sigma_{mm}} & \dots & \frac{\sigma_{mm}^2}{\sigma_{mm}\sigma_{mm}} \end{bmatrix} \quad (2.10)$$

Considerando novamente a matriz normalizada $Z = (V^{1/2})^{-1}(X - \mu)$ e com cada uma das variáveis também normalizadas, tem-se que $E(Z) = 0$, onde o zero denota um vetor de dimensão $n \times 1$ preenchidos com zeros e Z como sendo a matriz de covariância $Cov(Z) = (V^{1/2})^{-1}\Sigma(V^{1/2})^{-1} = \rho$. Então para o conjunto de dados normalizado, a matriz de covariância e a matriz de correlação são as mesmas. O i -ésimo componente principal da matriz normalizada $Z = [Z_1, Z_2, \dots, Z_m]$ é dado por $Y_i = e_i'Z$ onde e_i refere-se ao i -ésimo auto vetor e e_i' refere-se a transposta de e_i . Os componentes principais são combinações lineares Y_1, Y_2, \dots, Y_k das variáveis normalizadas em Z tais que as variâncias de Y_i são as maiores possíveis e Y_i não sendo correlacionadas. Logo pode-se escrever o primeiro componente principal como sendo a seguinte combinação linear:

$$Y_1 = e_1'Z = e_{11}Z_1 + e_{12}Z_2 + \dots + e_{1m}Z_m \quad (2.11)$$

Desta forma é expresso a maior variabilidade possível dentre as existentes combinações lineares para as variáveis da matriz Z . O primeiro componente principal é a combinação linear $Y_1 = e_1'Z$ que maximiza a variância $Var(Y_1) = e_1'\rho e_1$, o segundo componente principal é a combinação linear $Y_2 = e_2'Z$, porém Y_2 é independente de Y_1 e ainda que maximiza a variância $Var(Y_2) = e_2'\rho e_2$ e o i -ésimo componente principal é a combinação linear $Y_i = e_i'X$, porém sendo independente de todos os outros componentes principais Y_j , com $j < i$ e ainda maximizando a variância $Var(Y_i) = e_i'\rho e_i$.

Com isto os escalares $\lambda_1, \lambda_2, \dots, \lambda_m$, são chamados de *autovalores* da matriz B satisfazendo a condição $|B - \lambda I| = 0$ onde B é uma matriz de dimensão $m \times m$ e I é uma matriz identidade (matriz cuja diagonal todos seus componentes são iguais a um) de dimensão $m \times m$.

Já o *autovetor* e é definido pelo vetor e de dimensão $m \times 1$ diferente de zero da matriz B com $Be = \lambda e$, com λ sendo um *autovalor* de B . Com isto é possível obter os seguintes resultados para a PCA:

1. A variabilidade total nos dados normalizados é igual a soma das variâncias para cada vetor Z , que por sua vez é igual a soma das variâncias para cada componente – cujo resultado é igual a soma dos *autovalores* e consequentemente ao número total de variáveis:

$$\sum_{i=1}^m \text{Var}(Y_i) = \sum_{i=1}^m \text{Var}(Z_i) = \sum_{i=1}^m \lambda_i = m \quad (2.12)$$

2. A correlação parcial entre um dado componente e uma dada variável é uma função de um *autovetor* e um *autovalor*, sendo:

$$\text{Corr}(Y_i, Z_j) = e_{ij} \sqrt{\lambda_i} \quad i, j = 1, 2, \dots, m \quad (2.13)$$

onde (λ_1, e_1) , (λ_2, e_2) , ..., (λ_m, e_m) são os pares de *autovalores-autovetores* para a matriz de correlação ρ , que pode ser escrita da forma $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_m$. Ainda pode ser escrito o *coeficiente de correlação parcial* como o coeficiente que leva em consideração o efeito de todas as outras variáveis.

3. A proporção da variabilidade total na matriz Z que é explicada pelo i -ésimo componente principal é dada pela relação entre o i -ésimo *autovalor* pelo número de variáveis m .

De uma forma análoga a técnica de PCA, a Decomposição de Valores Singulares (DVS) funciona de forma semelhante. De posse destes conceitos é possível realizar a DVS em um banco de dados qualquer e com isto reduzir o espaço dimensional utilizado, ou seja, o número de variáveis de entrada (*descritores*) necessários para “descrever” o banco de dados da mesma forma que se fosse feita com o número original de variáveis iniciais será consideravelmente menor em virtude da utilização da técnica, consequentemente economizando recursos computacionais e ainda o tempo necessário para a análise. Deste modo, em um banco de dados é possível contabilizar a maior parte da variabilidade entre as palavras extraídas e seus respectivos documentos e assim identificar o espaço semântico latente que organiza as palavras e documentos na análise. De alguma maneira, assim que as dimensões podem ser identificadas, tem-se extraído o “significado” do que está implícito seja em termos de discussão ou ainda descrição nos documentos.

Tan (2008) mostra que com o advento do conteúdo digital, banco de dados e arquivos tem recebido mais atenção no que tange como a informação pode ser recuperada por toda a

comunidade que trabalha com Processamento de Linguagem Natural (PLN). Vários algoritmos foram propostos para a solução de problemas de mineração de textos tais como classificação de centróides, técnica de proximidade de vizinhança (*K-Nearest Neighbor*), árvores de decisão, redes neurais para classificação de grupos, entre outros. Leiter (2008) propõe a combinação do julgamento humano e sistemas automáticos de mineração de textos para que possa ser retirado informações de anotações em geral.

Batyrshin (2007) menciona que a tarefa de extrair dados significantes de um banco de dados pode ser útil para as atividades de gerenciamento e ainda auxiliar em decisões. O desenvolvimento das técnicas de mineração de textos para extrair informação de banco de dados pode ajudar neste caso. Como já enfatizado o principal objetivo é encontrar dados relevantes em uma massa de dados qualquer. Dentre os algoritmos citados anteriormente, somam-se as técnicas mais tradicionais para análise e mineração de textos, entre elas segmentação, agrupamento (*clustering*), classificação, indexação, sumarização, detecção de anomalias, descoberta de notas, previsões e regras associativas. Cada uma destas técnicas possui uma determinada particularidade que dependendo do problema em estudo apresenta um melhor ou pior resultado. Ainda as técnicas podem ser inclusive utilizadas em conjunto, por exemplo fazer o uso de uma tarefa de segmentação com efeitos no agrupamento e sumarização.

Estas tarefas podem ser mutuamente relacionadas, por exemplo a tarefa de segmentação pode ser usada para indexação, agrupamento, sumarização, etc. Uma vez que a complexidade do sistema aumenta, a senso de fazer a decisão correta diminui proporcionalmente. O mesmo é aplicado aos banco de dados onde as informações relevantes que são buscadas estão imersas em uma nuvem de palavras, onde é difícil para extrair tais palavras chave baseando-se somente na percepção humana para identificar problemas inerentes, a menos que tal problema já tenha alcançado uma significância que *apareça aos olhos* do analista.

A seguir, no **Capítulo 3** será mostrado como as redes neurais artificiais podem ser empregadas após o pré-processamento possível através da mineração de textos, apresentada aqui no **Capítulo 2**.

3. Reconhecimento Neural de Padrões em Dados de Texto

3.1 Introdução

Neste capítulo será mostrado uma breve revisão bibliográfica sobre RNA, com foco principal na rede *Multilayer Perceptron* que é um dos vários tipos existentes de RNAs existentes. A mesma será utilizada para o reconhecimento dos padrões entre os vários documentos analisados.

3.2 Contextualização ao Problema de Pesquisa

No *Capítulo 2* foi mostrado como foi feito um pré-processamento de cada registro bem como a posterior análise para a construção de uma tabela de descritores de cada registro. A partir desta tabela, onde cada linha corresponde a um documento e cada coluna consiste em um descritor (palavra chave que descreve um determinado documento) e somado a outras colunas que correspondem a outras variáveis qualitativas de um determinado registro, será construída a entrada e saída de valores para a RNA a ser modelada, treinada e validada.

A seguir será mostrada uma breve fundamentação teórica de RNA.

3.3 Redes Neurais Artificiais

3.3.1 O Cérebro Humano

De acordo com Haykin (1999), o sistema nervoso humano pode ser dividido em três estágios distintos para facilitar seu estudo e compreensão, sendo então responsável por receber informações, perceber e então fazer as decisões apropriadas. As informações recebidas na forma de estímulos são então convertidas para impulsos elétricos que posteriormente são enviados a rede de neurônios humana e ao cérebro, que então as processa e devolve as respostas ainda em impulsos elétricos que posteriormente serão responsáveis por gerar as respostas desejadas no corpo e por exemplo seus sistemas motores.

O estudo e entendimento do cérebro humano deu-se de forma simplificada com trabalhos pioneiros onde foi proposta a ideia dos neurônios como sendo a estrutura constituinte do cérebro. Tipicamente, os neurônios do cérebro humano são de cinco a seis vezes mais lento que uma porta lógica feita de silício, ou seja, eventos que venham a acontecer em um *chip* de silício acontecem na casa dos nanossegundos (10^{-9} s) enquanto que no neurônio biológico do cérebro humano tais eventos ocorrem na casa dos milissegundos (10^{-3} s). Mesmo assim, o cérebro humano lida com esta “baixa velocidade” quando

comparado a um chip de silício fazendo uso de uma massiva interconexão entre neurônios. Estima-se que dos dez milhões de neurônios do córtex do cérebro humano, o mesmo produz em torno de sessenta trilhões de sinapses ou conexões. Então de todo este emaranhado de conexões e neurônios resulta-se em um sistema eficiente seja do ponto de vista do processamento bem como do consumo de energia (o cérebro humano gasta aproximadamente 10^{-16} J (joules) enquanto computadores chegam a usar 10^{-6} J por operação por segundo).

Logo as sinapses são as estruturas elementares e unidades funcionais que mediam a interação entre os neurônios. O tipo mais comum de sinapse é o de origem química, que funciona quando uma pré-sinapse libera uma substância transmissora que difunde pela junção sináptica entre dois neurônios e então atua em um processo pós-sináptico. Então uma sinapse converte um sinal pré-sináptico em um sinal químico e então em um sinal elétrico pós-sináptico. Na descrição clássica de uma organização neural, é assumido que uma sinapse é uma conexão simples que pode gerar uma excitação ou uma inibição, mas não ambas no neurônio que recebe o sinal.

Na dura tarefa de aprender, o cérebro humano é moldado durante a vida do ser, o que acontecesse massivamente até os dois anos de idade. Nesta fase, a qual é denominada de fase plástica, é quando o cérebro se adapta e recebe estímulos do ambiente que o cerca. No cérebro adulto, a plasticidade pode ainda ser alcançada por dois mecanismos, o primeiro pela criação de conexões sinápticas entre os neurônios existentes e a o segundo pela modificação das conexões sinápticas já existentes. Tais conexões são de entrada ou saída de informações. Os axônios constituem como sendo as linhas responsáveis pelo tráfego e transmissão de informações, enquanto que os dendritos constituem as zonas responsáveis pelo recebimento das informações oriundas de outros neurônios. Enquanto que o axônio é constituído por uma superfície suave, algumas ramificações e um comprimento extenso, um dendrito possui uma superfície totalmente irregular e muitas ramificações. Já o neurônio, pode receber 10.000 ou mais conexões sinápticas e pode projetar-se em centenas de outros neurônios. A maioria dos neurônios codifica a saída de informações na forma de breves pulsos de tensão. Estes pulsos, comumente conhecidos como potenciais de ação ou ainda picos, originados próximo ou mesmo no corpo do neurônio e então propagando através dos neurônios subsequentes a uma velocidade e amplitude constante. A razão pela qual do uso de potenciais de ação para comunicação entre neurônios deve-se principalmente a física dos axônios, que comportam-se de forma semelhante a uma longa linha de transmissão, de alta resistência elétrica e uma grande capacitância. Ambas destas características elétricas são distribuídas pelos axônios. Então uma breve análise do mecanismo de propagação revela que quando uma tensão elétrica

é aplicada no fim de um axônio, a mesma decai exponencialmente com a distância, caindo a um nível insignificante quando a mesma alcança a outra ponta do axônio. Então o uso de potenciais de ação como uma maneira de contornar este “problema de transmissão”.

Até aqui foi falado de como é formado as estruturas básicas do cérebro humano, de forma que desde a menor parte do cérebro, até o agrupamento de neurônios em conjuntos de células especializadas em uma determinada tarefa, constituindo então porções maiores do cérebro que organizam-se em estruturas anatômicas responsáveis por tarefas especializadas tais como controle de tarefas motoras, audição, visuais, sensoriais, entre outras.




Figura 3.1 – Típico Neurônio do Cérebro Humano

3.3.2 Modelos de Neurônios Artificiais

Um neurônio é uma unidade de processamento de informação básica, que é fundamental para a operação de uma rede neural. A **Figura 3.2** mostra o modelo de um neurônio, o qual forma a base para o desenvolvimento de uma rede neural artificial. Tal como no neurônio humano e seus três elementos básicos, por analogia identificam-se os três elementos básicos de um neurônio artificial:

- 1) Um *conjunto de sinapses* ou elementos de conexão, cada um sendo caracterizado por um *peso* determinado. Especificamente, um sinal qualquer na entrada x_j de uma sinapse j conectada ao neurônio k é então multiplicada pelo peso w_{kj} atribuído a esta conexão sináptica. Diferente de uma conexão sináptica do cérebro humano, o peso sináptico do neurônio artificial pode variar em uma determinada faixa de valores que incluem tanto valores positivos bem como valores negativos;

- 2) Um *combinador linear* que é responsável pela soma dos sinais de entrada, acompanhados por sua vez do respectivo peso das sinapses, que constituem por sua vez uma combinação linear dos mesmos;
- 3) Uma *função de ativação* para limitar a amplitude do sinal de saída do neurônio. A função de ativação é também referida em algumas vezes como *squashing function*, ou seja uma função limitadora ou ainda em outras palavras uma função que comprime uma faixa de valores que por exemplo poderiam variar entre zero e dez em uma outra faixa de valores compreendida entre zero e um. Tipicamente, pode-se dizer que a amplitude de valores foi normalizada, ou seja, pode ser escrita em um intervalo de valores fechado $[0,1]$.

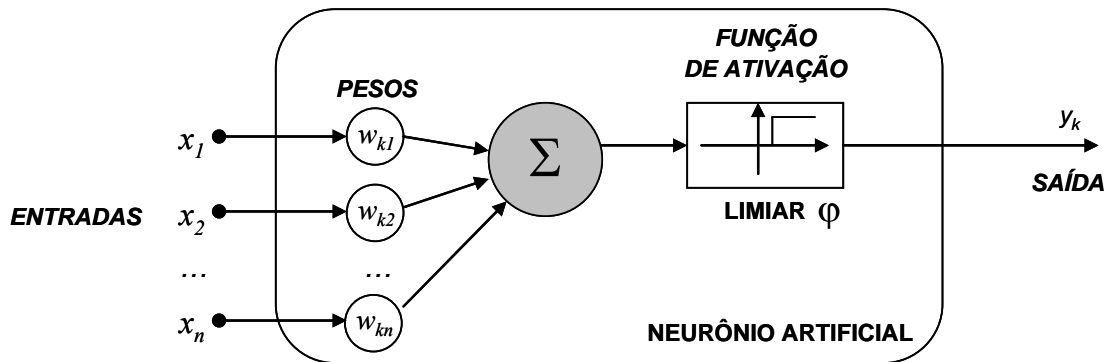


Figura 3.2 – Modelo do Neurônio Artificial

Um modelo de neurônio artificial também inclui em sua constituição um viés ou uma tendenciosidade aplicada (do inglês *bias*), representado por b_k . O viés tem o efeito de aumentar ou diminuir a entrada da função de ativação, dependendo se é positiva ou negativa. Em termos matemáticos, o neurônio artificial pode ser descrito pelo seguinte par de equações:

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (3.1)$$

$$y_k = \varphi(u_k + b_k) \quad (3.2)$$

onde x_1, x_2, \dots, x_n são os *sinais de entrada*; e $w_{k1}, w_{k2}, \dots, w_{km}$ são os *pesos sinápticos* dos neurônios; u_k é a *saída do neurônio* devida aos seus respectivos sinais de entrada; b_k é o *viés associado*; φ é a *função de ativação*; e y_k é o *sinal de saída* do neurônio. O uso do viés b_k tem um efeito de uma transformação afim (do inglês *affine transformation*) aplicado a saída u_k , como segue:

$$v_k = u_k + b_k \quad (3.3)$$

Em particular, dependendo se o viés é positivo ou negativo, a relação entre a saída induzida v_k de um neurônio k e a respectiva saída u_k é então modificada como mostra o gráfico na **Figura 3.3** :




Figura 3.3 – Relação entre Saída do Combinador Linear e Potencial de Ativação

O viés é um parâmetro externo ao neurônio artificial k . O mesmo pode ser observado na equação (3.2). Logo, as equações (3.1) e (3.2) podem ser escritas como segue:

$$v_k = \sum_{j=1}^m w_{kj} x_j \quad (3.4)$$

$$y_k = \varphi(v_k) \quad (3.5)$$

Logo uma forma de considerar o viés no modelamento do neurônio artificial, é adicioná-lo na forma de uma nova sinapse com entrada fixa e cujo peso será o próprio viés, o que é mostrado nas equações (3.6) e (3.7) e de forma ilustrativa na **Figura 3.4** a seguir :

$$x_0 = +1 \quad (3.6)$$

$$w_{k0} = b_k \quad (3.7)$$




Figura 3.4 – Modelo do Neurônio Artificial com Viés Aplicado

Embora que os modelos das duas figuras possam parecer diferentes, eles são matematicamente equivalentes.

Quanto as funções de ativação do neurônio, denotadas por $\varphi(v)$, define-se a saída de um neurônio em termos do potencial de ativação v . Pode-se enumerar três tipos básicos de funções de ativação:

1) Função Limiar (Degrau Unitário)

A **Figura 3.5** mostra a Função Limiar. Para este tipo de função de ativação, tem-se:

$$\varphi(v) = \begin{cases} 1 & \text{se } v \geq 0 \\ 0 & \text{se } v < 0 \end{cases} \quad (3.8)$$




Figura 3.5 – Função Limiar (Degrau Unitário)

Para a saída do neurônio k cuja função de ativação comporta-se como a função limiar é:

$$y_k = \begin{cases} 1 & \text{se } v_k \geq 0 \\ 0 & \text{se } v_k < 0 \end{cases} \quad (3.9)$$

onde v_k é o potencial de ativação do neurônio, ou seja:

$$v_k = \sum_{j=1}^m w_{kj} x_j + b_k \quad (3.10)$$

Tal neurônio é referenciado na literatura como modelo de McCulloch-Pitts, em reconhecimento ao trabalho pioneiro conduzido por McCulloch e Pitts em 1943. Neste modelo, a saída de um neurônio é igual a um, caso o potencial de ativação daquele neurônio é um valor não-negativo e igual a zero quando esta condição não se cumprir.

2) Função definida por partes (*Piecewise*):

Para este tipo de função de ativação, tem-se:

$$\varphi(v) = \begin{cases} 1 & \text{se } v \geq +\frac{1}{2} \\ v + \frac{1}{2} & \text{se } +\frac{1}{2} > v > -\frac{1}{2} \\ 0 & \text{se } v < -\frac{1}{2} \end{cases} \quad (3.11)$$

onde o fator de amplificação dentro da região linear de operação é assumido como sendo uma unidade. Desta forma uma função de ativação pode ser vista como uma aproximação de um amplificador não-linear. As seguintes duas situações podem ser vistas como formas especiais da função definida por partes:

- Um *combinador linear* surge se na região linear de operação é mantida sem operar em saturação;
- A função reduz a uma função de pico (*threshold function*) se o fator de amplificação da região linear for feito infinitamente grande.




Figura 3.6 – Função Definida por Partes

3) Função Sigmoid

A função sigmoid, cujo gráfico é uma curva em forma de “S” é de longe a forma mais comum de função de ativação usada na construção de uma rede neural artificial. A função é definida como sendo estritamente crescente, que por sua vez exibe um balanço gracioso entre o linear e o não-linear. A função sigmoid pode ser definida por uma *função logística*, definida por:

$$\varphi(v) = \frac{1}{1 + e^{-av}} \quad (3.12)$$

onde a é o parâmetro que determina a inclinação (*slope*) da função sigmoid. Logo variando o parâmetro a , obtêm-se funções sigmoid de diferentes inclinações, conforme pode-se ver na **Figura 3.7**:




Figura 3.7 – Função Sigmoid

Existem ainda vários outros tipos de funções de ativação que podem ser empregadas de diferentes maneiras. Dependendo do tipo de problema estudado, além destas funções de ativação mostradas anteriormente, a **Tabela 3.1** mostra outros exemplos de funções para o modelamento de uma RNA:

Função	Definição	Intervalo
Identidade	x	$(-\infty, +\infty)$
Logística (Sigmoid)	$\frac{1}{1 + e^{-x}}$	$(0, +1)$
Hiperbólica	$\frac{e^x - e^{-x}}{e^x + e^{-x}}$	$(-1, +1)$
Exponencial	e^{-x}	$(0, +\infty)$
Softmax	$\frac{e^x}{\sum_i e^{x_i}}$	$(0, +1)$
Soma	$\frac{x}{\sum_i x_i}$	$(0, +1)$
Raiz Quadrada	\sqrt{x}	$(0, +\infty)$
Seno	$sen(x)$	$[0, +1]$
Rampa	$\begin{cases} -1 & x \leq -1 \\ x - 1 & -1 < x < +1 \\ +1 & x \geq +1 \end{cases}$	$[-1, +1]$
Passo	$\begin{cases} 0 & x < 0 \\ +1 & x \geq 0 \end{cases}$	$[0, +1]$

Tabela 3.1 – Algumas Funções de Ativação para RNA

3.3.3 Topologias de Rede

O potencial e a flexibilidade das redes neurais estão intimamente relacionados à maneira como os neurônios estão conectados entre si. Deve-se ter em mente que cada neurônio recebe, processa e transmite uma dada entrada.

Pode-se classificar as topologias quanto ao método de propagação da informação recebida. No caso da topologia *feedforward* o fluxo da informação é unidirecional. Ao conjunto de neurônios que recebem informação em um mesmo instante atribui-se o nome de *camada*. Uma rede pode ser formada por várias camadas. As camadas que não estão ligadas às entradas e nem às saídas denominam-se *Camadas Ocultas*. Existem ainda as redes com topologia *realimentadas*, ou seja cada neurônio recebe o sinal de todos os outros e ainda de si próprio (com utilização em sistemas dinâmicos).

Constituindo as principais topologias, a **Figura 3.8** ilustra na esquerda como ocorre a propagação para frente (feedforward) e na direita as realimentadas:




Figura 3.8 – Redes com Propagação para Frente (*Feedforward*) e Realimentação

3.3.4 Tipos de Aprendizagem e Adaptação dos Pesos

Uma vez definida a topologia, o próximo passo é optar entre os tipos de aprendizagem para que a rede neural possa ser treinada. Isso significa que os graus de liberdade que a rede dispõe para solucionar a tarefa requerida têm que ser adaptados de uma maneira ótima, o que, tecnicamente, implica na modificação dos pesos w_{ij} segundo algum algoritmo. Esta modificação se dá na fase de treinamento da rede mediante a utilização de um conjunto T de n exemplos de treino. Esta capacidade de adaptação pode ser classificada em duas categorias: a aprendizagem *supervisionada* e a *não-supervisionada*.

A *aprendizagem supervisionada* é aquela na qual cada exemplo do conjunto de treinamento está acompanhado pelo valor desejado. Isto significa que o conjunto T tem n pares de exemplos (x_p, y_p) . Um exemplo deste tipo de aprendizagem é a regressão linear, onde o objetivo é a determinação dos coeficientes linear e angular. O algoritmo utilizado tenta minimizar a diferença entre y_p e a resposta encontrada.

A *aprendizagem não-supervisionada* é aquela que só tem um tipo de informação disponível: x_p . Neste caso, a tarefa da aprendizagem é descobrir correlações entre os exemplos de treino. A princípio, o número de categorias ou classes em que os dados estão agrupados não é conhecido, sendo uma tarefa da rede identificá-los a partir de atributos estatísticos.

Durante o processo de aprendizagem, os pesos normalmente percorrem uma modificação iterativa segundo a necessidade determinada pelo algoritmo de aprendizagem. Os pesos são inicializados aleatoriamente. O algoritmo de aprendizagem realiza um número pré-

determinado de iterações até que uma dada condição de parada seja atingida conforme a equação (3.13):

$$w_{ij}^{(l+1)} = w_{ij}^l + \Delta w_{ij}^l \quad (3.13)$$

Segundo a hipótese de Hebb (1949) *apud* Haykin (1999), o peso de ligação entre dois neurônios que estão ativos ao mesmo tempo deve ser reforçado, tal que:

$$\Delta w_{ij} = \eta y_i y_j \quad (3.14)$$

onde a taxa de aprendizagem η é um fator de escala positivo que determina a velocidade da aprendizagem. Uma outra regra também importante para a adaptação dos pesos das conexões sinápticas é a Regra Delta.

Tal regra possui um objetivo bem visível. A Regra Delta foi proposta por Widrow-Hoff (1960) *apud* Haykin (1999). A rede calcula na saída, em um neurônio i , uma função y'_i . Como se conhece o valor de y_i na aprendizagem supervisionada, pode calcular o erro e_i entre o calculado e o desejado, tal que $e_i = y_i - y'_i$. O peso entre o neurônio i e o neurônio j que é responsável por este erro, devem ser modificados proporcionalmente à ativação e ao erro, tal que:

$$\Delta w_{ij} = \eta y_i y_j = \eta (y_i - y'_i) y_j \quad (3.15)$$

Neste caso, o objetivo do algoritmo é minimizar o erro entre os valores calculados pela rede os valores fornecidos no conjunto de treinamento.

Ainda vale citar a *aprendizagem competitiva*, que é aquela na qual um único neurônio da rede é ativado. Isso significa que todos os outros neurônios terão ativação igual a zero. O efeito é que os pesos se deslocarão em direção ao estímulo de entrada da rede x .

$$\Delta w_{ij} = \eta (x_j - w_{ij}) y_i \quad (3.16)$$

3.3.5 Tipos de Redes Neurais

Como já comentado anteriormente, as redes com propagação para frente (*feedforward*) caracterizam-se por aprendizagem supervisionada, organizada em camadas e com propagação da informação unidirecional e para frente e, em geral, possuem valores de saída binários. O Adaline (saídas contínuas) e o MLP (*Multilayer Perceptron*) são variantes deste tipo de rede. Complementando ainda outros tipos de redes disponíveis, cada uma com sua particularidade e utilização para resolução de problemas, tem-se a RBF (*Radial Basis Function*), PNN (*Probabilistic Neural Network*), GRNN (*Generalized Regression Neural Networks*) entre alguns dos tipos de redes que trabalham com aprendizagem supervisionada existentes (HAYKIN, 1999; BISHOP, 1995).

3.3.6 Perceptrons

São ideais para atividades de classificação tais como: reconhecimento automático de caracteres, detecção de falhas, impressões digitais, voz, íris etc.

A função implementada pelo perceptron substitui a função escada do neurônio de McCulloch e Pitts por uma função sinal do tipo $\text{sgn}(z)=1$ se $z \geq 0$ e $\text{sgn}(z)=-1$, se $z < 0$. Pode-se fazer o limiar $\mu = -w_0$, introduzindo um novo valor de entrada fixo $x_0 = 1$. Genericamente, a regra de classificação do perceptron pode ser escrita como:

$$d(x) = \text{sgn}\left(\sum_{j=0}^D w_j x_j\right) \quad (3.17)$$

A função $d(x)$ fornece uma resposta binária sobre “de que lado” está o objeto $x = (x_1, x_2)^T$, permitindo assim, uma classificação linear entre duas classes, conforme mostrado na **Figura 3.9**:




Figura 3.9 – Problema de classificação de eventos linearmente separáveis.

O algoritmo de adaptação dos pesos classifica todos os objetos de treino através de $d(x)$. A classe verdadeira de x está disponível no valor alvo t . Se nenhum erro de classificação ocorrer, $d(x)=t$. Contudo, se os erros ocorrerem, todos os objetos x que provocaram um erro são utilizados para modificar os pesos W , de modo que o número de erros tenda a desaparecer. Esta regra pode ser escrita como:

$$\Delta w_j = \eta t x_j \text{ se } d(x) \neq t \text{ e } \Delta w_j = 0, \text{ se } d(x) = t \quad (3.18)$$

3.3.7 Adaline

O termo Adaline é a junção das palavras *Adaptive Linear Neuron*, ou seja, Neurônio Linear Adaptável.

A diferença principal em relação ao perceptron é que a saída do Adaline é contínua, ou seja, os valores de saída estão no domínio dos números reais. A função calculada $d(x)$ é simplesmente a combinação linear dos pesos e das entradas, ou, de maneira equivalente, o produto interno entre o vetor de pesos e o vetor das entradas.

$$d(x) = \sum_{j=0}^D w_j x_j = w^T x \quad (3.19)$$

O objetivo do algoritmo de aprendizagem está na busca dos pesos que exibem uma propriedade ótima em relação a função a ser calculada. Uma escolha natural é a diferença entre o valor desejado t_p para o exemplo x_p e o valor calculado pela rede $d(x_p)$. Como o erro pode ser positivo ou negativo, calcula-se o quadrado dos termos, fazendo com que a diferença não se cancele. Assim, tem-se que:

$$e^2(x_p) = (t_p - d(x_p))^2 = (t_p - w^T x_p)^2 \quad (3.20)$$

O objetivo é minimizar o erro, considerando-se a média de todos os n exemplos. Desse modo, o erro quadrático médio pode ser escrito como:

$$EQM = \frac{1}{n} \sum_{p=1}^n (t_p - w^T x)^2 \quad (3.21)$$

A solução determinística para esse tipo de problema é encontrar o vetor de pesos w que minimize o EQM . Agrupando-se os x_p elementos de treinamento em uma única matriz X , tem-se que:

$$w = (X^T X)^{-1} X^T t \quad (3.22)$$

Esta solução aplica-se a problemas de natureza linear. Com problemas de natureza não-linear a técnica adequada é a da *Gradiente Descendente*. Esta técnica utiliza o princípio de que o erro quadrático médio é uma função dos pesos w_{min} da rede. O objetivo geral do algoritmo de aprendizagem é chegar iterativamente a um mínimo global w_{min} . A única informação conhecida na iteração l é o valor do erro $EQM(w^{(l)}) = E(w^{(l)})$ para o peso $w^{(l)}$ atual. Supõe-se que a função do erro seja derivável em todo o domínio. Isto significa que o gradiente da função erro existe.

O gradiente é um vetor e aponta na direção do crescimento da função E . Conseqüentemente, o gradiente negativo aponta na direção do decréscimo. A tentativa para se alcançar o mínimo da função é, então, a modificação do peso na iteração l para a iteração $l+1$ na direção do gradiente negativo $-\nabla E$. Para se controlar a velocidade da modificação do peso, usa-se a taxa de aprendizagem como fator de escala. Assim, a regra de adaptação de peso por descida de gradiente pode ser escrita como:

$$w^{(l+1)} = w^{(l)} + \Delta w^{(l)} = w^{(l)} - \eta \nabla E^{(l)} \quad (3.23)$$

Neste ponto fica claro porque se necessita de funções de ativação contínuas e diferenciáveis em todo o domínio de \mathbb{R} .

O algoritmo se inicia com um valor aleatório para peso $w(0)$ na iteração 0 e se aplica até que a diferença entre dois conjuntos de pesos consecutivos seja menor do que uma dada tolerância admitida.

3.3.8 Definição da Função Erro

A função Erro pode ser definida por duas formas:

a) Por aprendizagem Estocástica: a apresentação dos exemplos se dá em ordem aleatória e os pesos são modificados depois de cada exemplo apresentado. Neste caso, calcula-se o gradiente relativo ao peso individual w_j como:

$$\begin{aligned} \nabla E_j &= \frac{\partial E}{\partial w_j} = \frac{\partial [e^2(x_p)]}{\partial w_j} = 2e(x_p) \frac{\partial [e(x_p)]}{\partial w_j} \\ \nabla E_j &= 2e(x_p) \frac{\partial (t_p - \sum_{j=0}^D w_j x_{pj})}{\partial w_j} = -2e(x_p) x_{pj} \end{aligned} \quad (3.24)$$

b) Por aprendizagem em Lote ("Batch"): a apresentação dos exemplos se dá de uma só vez e os pesos são modificados depois que todos os exemplos são apresentados.

$$\nabla E_j = \frac{\partial E}{\partial w_j} = -2 \sum_{p=1}^n e(x_p) x_{pj} \quad (3.25)$$

3.3.9 Multilayer Perceptron (MLP) e Backpropagation

Uma vez exposto os tipos clássicos de redes, pode-se mostrar a rede multicamadas, que consiste em qualquer perceptron com pelo menos uma camada oculta é um perceptron multicamada (*Multilayer*).

Considere-se o caso de um perceptron com uma única camada oculta (a generalização para mais que uma camada oculta é direta e a teoria se aplica sem alteração).

Um neurônio recebe várias entradas da camada anterior e calcula uma combinação linear dessas variáveis. O resultado da combinação linear passa pela função de ativação, que neste caso será definida como sigmoideal. Propositadamente, será utilizada mais do que uma saída. Isto implica que a saída será representada por um vetor $d = (d_1, \dots, d_c)^T$ de c funções individuais d_i calculadas. Desse modo, a rede realiza um mapeamento de um vetor

multidimensional x para outro vetor multidimensional d . A camada oculta tem H neurônios. Utiliza-se eventualmente uma entrada constante e igual a 1 também na camada oculta. Um peso entre a variável de entrada x_j e o neurônio h da camada oculta é representado como w_{hj} . O conjunto de todos estes pesos podem ser agrupados na matriz W_h . Analogamente, W_i é o conjunto de pesos w_{hi} . A **Figura 3.10** mostra como é a arquitetura de uma rede formada por perceptrons multicamadas:




Figura 3.10 – Arquitetura de uma rede formada por perceptrons multicamadas.

Desse modo, pode se representar a função do perceptron multicamada como mostrado na equação (4.26) bem como a respectiva função de ativação conforme mostrada na equação (4.27) :

$$d_i(x) = g \left(\sum_{h=0}^H w_{ih} g \left(\sum_{j=0}^D w_{hj} x_j \right) \right) \quad (3.26)$$

$$g(z) = \frac{1}{1 + e^{-z}} \quad (3.27)$$

Esta função é capaz de realizar cálculos não lineares, bem como pode ser utilizada em problemas de separação de classes não linearmente separáveis. É muito útil em regressões e previsões.

Uma das grandes vantagens desta técnica é que o MLP é um aproximador universal de funções. Isto significa que, desde que os pesos sejam bem adaptados e o número de neurônios seja suficientemente adequado, o cálculo desejado é atingido.

Pode-se definir o procedimento de adaptação dos pesos de um MLP de maneira análoga ao do Adaline. Uma vez que o número de saídas d_i aumentou para c , a diferença entre os valores desejados para o exemplo e os valores calculados pela rede transforma-se em uma diferença entre dois vetores, representada pela distância Euclidiana quadrática, tal que:

$$e^2(x_p) = \|t_p - d(x_p)\|^2 = \sum_{i=0}^c (t_{pi} - d_i(x_p))^2 \quad (3.28)$$

Do mesmo modo, o erro quadrático médio é dado por:

$$EQM = \frac{1}{n} \sum_{p=1}^n e^2(x_p) = \frac{1}{n} \sum_{p=1}^n \sum_{i=0}^c (t_p - d_i(x_p))^2 \quad (3.29)$$

Segundo Haykin (1999), na adaptação dos pesos da camada oculta para a camada de saída pode-se utilizar a regra Delta, e entre a camada oculta e a camada de entrada, a regra Delta generalizada. Considerando-se a aprendizagem orientada apenas a cada exemplo x_p , e calculando-se o gradiente em relação aos pesos da camada oculta para a camada de saída e o gradiente em relação aos pesos da entrada para a camada oculta, tem-se:

$$d_i(x_p) = g_i = g\left(\sum_i i\right) = g\left(\sum_{h=0}^H w_{ih} g_h\right) = g\left(\sum_{h=0}^H w_{ih} g\left(\sum_h h\right)\right) = g\left(\sum_{h=0}^H w_{ih} g\left(\sum_{j=0}^D w_{hj} x_j\right)\right) \quad (3.30)$$

Aplicando-se a regra Delta (Camada Oculta para Camada de Saída), tem-se:

$$\begin{aligned} \nabla E_{ih} &= \partial E / \partial w_{ih} = \partial e^2 / \partial w_{ih} = \partial \left(\sum_{i=1}^c e_i^2 / \partial w_{ih} \right) \\ &= \partial \left(\sum_{i=1}^c (t_i - g_i)^2 / \partial w_{ih} \right) = \sum_{i=1}^c \partial (t_i - g_i)^2 / \partial w_{ih} \\ &= 2 \left(\sum_{i=1}^c (t_i - g_i) (\partial g_i / \partial w_{ih}) \right) = -2(t_i - g_i) (\partial g_i / \partial w_{ih}) = -2e_i \partial g_i / \partial w_{ih} \\ &= -2e_i |g_i(1 - g_i) (\partial \sum_i / \partial w_{ih})| = -2e_i |g_i(1 - g_i) g_h| = -2\delta_i g_h \end{aligned} \quad (3.31)$$

onde a quantidade $\delta_i = e_i g_i' = e_i (g_i(1 - g_i))$ foi definida como o *delta* da camada de saída.

Aplicando-se a regra Delta generalizada (Entrada para Oculta), tem-se:

$$\begin{aligned}
\nabla E_{hj} &= \partial E / \partial w_{hj} = \partial e^2 / \partial w_{hj} = \partial \left(\sum_{i=1}^c e_i^2 / \partial w_{hj} \right) = \partial \left(\sum_{i=1}^c (t_i - g_i)^2 / \partial w_{hj} \right) \\
&= \sum_{i=1}^c \partial (t_i - g_i)^2 / \partial w_{hj} = -2 \sum_{i=1}^c (t_i - g_i) \partial g_i / \partial w_{hj} \\
&= -2 \sum_{i=1}^c e_i (\partial g(\Sigma_i) / \partial w_{hj}) = -2 \sum_{i=1}^c e_i g_i (1 - g_i) (\partial \Sigma_i / \partial w_{hj}) \\
&= -2 \sum_{i=1}^c e_i g_i (1 - g_i) \left| \partial \left(\sum_{h=0}^H w_{ih} g_h \right) / \partial w_{hj} \right| \\
&= -2 \sum_{i=1}^c e_i g_i (1 - g_i) \left| \left(\sum_{h=0}^H w_{ih} \partial g_h \right) / \partial w_{hj} \right| \\
&= -2 \sum_{i=1}^c e_i g_i (1 - g_i) \left| w_{ih} g_h (1 - g_h) x_j \right| \\
&= -2 g_h (1 - g_h) \sum_{i=1}^c e_i g_i (1 - g_i) w_{ih} x_j = -2 \delta_h x_j \tag{3.32}
\end{aligned}$$

onde a quantidade $\delta_h = g_h \sum_{i=1}^c \delta_i x_j$ foi definida como o *delta* da camada escondida.

Parece evidente que os deltas das camadas anteriores são propagados “para trás”, justificando-se assim, a expressão retropropagação de erro.

3.3.10 Redes com Realimentação

Todos os modelos até agora apresentados (perceptron e adaline) são redes com propagação para frente. Isso significa que a informação é processada unidirecionalmente dentro da rede. Como informação, será agora descrito como funciona uma rede por realimentação, conforme foi ilustrado na **Figura 3.8**.

Esse tipo de processamento supõe que não há comportamento dinâmico da rede, ou seja, a ativação dos neurônios depende deterministicamente das entradas. Por outro lado, pode-se conceber uma rede que realimenta os valores calculados como entradas novamente, o que provoca o cálculo de valores modificados nas saídas, que por sua vez novamente são realimentadas. Certamente esse tipo de rede exibe um comportamento dinâmico dos seus valores, isto é, uma modificação dos valores ao longo do tempo, dado um único estímulo inicial. O conjunto de valores de saída atuais dos neurônios chama-se o *estado* da rede. Desejável é um comportamento estável. Isso significa que depois de um estímulo inicial os valores de saída caminham para uma constante.

Para apresentar os conceitos de redes com realimentação e comportamento dinâmico utilizar-se-á o modelo de Hopfield. Neste modelo de rede, entradas x_j e saídas x_i do neurônio i são valores binários, tal que o valor 1 representa um estado “ativo” e o valor -1 , “inativo”. Supondo um neurônio do tipo McCulloch-Pitts, com pesos w_{ij} entre neurônio i e neurônio j , com a função sinal como ativação, tal que $\text{sgn}(z) = 1$ se $z \geq 0$ e $\text{sgn}(z) = -1$ se $z < 0$ e um viés $\mu = 0$, pode-se formular a regra de adaptação dinâmica da saída do neurônio i como:

$$x_i = \text{sgn} \left(\sum_{j=0}^D w_{ij} x_j \right) \tag{3.33}$$

Em princípio não se distinguem entre variáveis de entrada x_j e de saída x_i porque a saída de um neurônio pode servir como entrada realimentada do mesmo neurônio. Tendo uma rede de H neurônios, o estado atual da rede caracteriza-se por um vetor de dimensão H com valores de 1 ou -1 . O comportamento dinâmico é a mudança de estado de $x(t)$ no instante t para um estado $x(t+\Delta t)$ no instante $t+\Delta t$. A rede é dita estável quando $x(t+\Delta t) = x(t)$ para todo $\Delta t > 0$.

O objetivo da rede é memorizar n padrões x_p de um conjunto de padrões T . A rede deve responder nas saídas com o estado $x(t)=x_p$ quando esse mesmo estado for apresentado inicialmente à rede. A resposta deve ser também o padrão memorizado, mesmo que o estímulo inicial seja apenas parecido com um dos padrões memorizados. A essa capacidade de recuperar informações memorizadas denomina-se *memória associativa*.

3.3.11 Estabilidade e Aprendizagem

Quais são as condições para que a rede seja estável? Se houvesse um único padrão $x = (x_1, \dots, x_H)^T$ o estado calculado pela rede segundo a equação (3.33) deveria ficar inalterado para cada neurônio $i = 1, \dots, H$. Substituindo-se o peso w_{ij} pela expressão $x_i(t) \cdot x_j(t)$ na equação (3.30), obtem-se:

$$\begin{aligned} &= x_i(t + \Delta t) \\ &= \operatorname{sgn} \left(\sum_{j=0}^D x_j(t) \cdot x_i(t) \cdot x_j(t) \right) = \operatorname{sgn} \left(\sum_{j=0}^D x_j(t) \cdot x_i(t) \cdot x_j(t) \right) \\ &= \operatorname{sgn} \left(\sum_{j=0}^D x_i(t) \cdot 1 \right) = \operatorname{sgn} (D \cdot x_i(t)) = x_i(t) \end{aligned} \quad (3.34)$$

Normalizando pelo número de neurônios presentes na rede, pode-se definir a seguinte regra de adaptação dos pesos para um padrão:

$$w_{ij} = \frac{1}{H} x_i \cdot x_j \quad (3.35)$$

Uma rede treinada por esta regra vai recuperar o padrão ensinado x mesmo quando a metade das entradas esteja diferente do padrão. Um estímulo inicial parecido com x converge para x . No caso de n padrões diferentes a extensão da regra caracteriza-se pela superposição do peso para todos os padrões. Neste caso, a Regra de Hebb Generalizada torna-se:

$$w_{ij} = \frac{1}{H} \sum_{p=0}^n x_{pi} \cdot x_{pj} \quad (3.36)$$

onde x_{pi} é o estado do neurônio i para o padrão p .

Na sequência, o **Capítulo 4** irá abordar a análise dos resultados empregando tanto a mineração de textos mostrada no **Capítulo 2**, como as RNAs mostradas aqui no **Capítulo 3**.

4. Análise dos Resultados

4.1 Introdução

No *Capítulo 2* foi mostrado uma breve revisão sobre mineração de textos e como esta técnica pode ser utilizada para a extração e construção de uma matriz de registros por descritores através do uso de informações de um banco de dados de texto não estruturado e expressá-los de forma quantitativa utilizando os diversos tipos de transformações existentes (binária, log, etc.). Já no *Capítulo 3* foi mostrada uma breve revisão bibliográfica de redes neurais artificiais (RNA) disponíveis para modelagem de problemas, bem como sua utilização para a previsão de eventos baseados em entradas fornecidas e conhecidas.

Neste capítulo espera-se que com a utilização destas duas técnicas distintas possa ser modelado um banco de dados na forma de variáveis de entrada através de um pré-processamento de textos valendo-se da mineração de dados e posteriormente a utilização de RNA para separar e classificar por grupos de resposta, com isto prevendo o resultado de eventos dada certas condições de entrada das variáveis em estudo. Para a modelagem em questão optou-se pela utilização de um tipo de RNA bastante conhecida na literatura por sua flexibilidade e versatilidade na modelagem de problemas de classificação que é a RNA do tipo *Multilayer Perceptron* (MLP).

4.2 Banco de Dados

A coletânea de registros que forma o banco de dados, objeto de estudo deste trabalho, é formada por registros em texto plano (não estruturado) na língua inglesa. Originalmente o banco de dados apresentava vários registros incompletos que foram removidos, pois não acrescentavam relevância ao trabalho, uma vez que tais registros carecem de informações em sua totalidade. Outros registros que não estavam na língua inglesa tais como registros em polonês, espanhol, italiano, etc. também não foram considerados neste trabalho.

O período a ser analisado corresponde uma massa de registros coletada entre os anos de 2004 e 2008, agrupando diversas informações conforme já discutidas no *Capítulo 1* (por exemplo: descrição do problema reportado e ação realizada, tempo de atraso, categorização do sistema que falhou, entre outros). Tal massa de dados se fosse medida em termos de números de componentes analisados na aeronave corresponderia em torno de quase 30% do número total de componentes (relativos ao total da aeronave). Quanto ao número de registros e a respectiva distribuição, a base de dados é formada de acordo com a *Tabela 4.1*:

Ano	Registros
2004	194
2005	2258
2006	2011
2007	3156
2008	8141
Total	15760

Tabela 4.1 – Banco de Dados

A diferença de dados coletados durante os anos é coerente com a quantidade de aeronaves em operação, ou seja, no ano de 2004 o número de registros coletados é inferior quando comparado com o ano de 2008, onde já existiam muito mais aeronaves em operação.

Em termos financeiros um operador chega a gastar em peças de reposição cifras na ordem de milhares de dólares para manter um estoque de peças, uma vez que o tempo de entrega de uma peça no ambiente aeronáutico pode variar desde uma semana para até dois meses, dependendo da complexidade e valor agregado da mesma. Então para que a aeronave não fique parada quando espera uma outra peça de reposição, várias são as estratégias adotadas tais como uso de estoques rotativos (quando a peça defeituosa é devolvida ao fabricante e o fabricante repõe ao operador com uma peça já reparada enquanto trabalha no conserto da peça devolvida anteriormente). Conseqüentemente um sistema que visa a diminuição do tempo necessário para manutenção e diagnóstico de padrões de falhas é de grande valia neste sentido, uma vez que uma peça defeituosa poderá retornar ao serviço em um intervalo de tempo menor do que o previsto. Logo isto também impacta no estoque a ser mantido, pois se peças retornam em um intervalo de tempo reduzido, o estoque também pode ser reduzido. Um outro benefício é um sistema que pode apontar padrões de falhas e comportamentos em avançado para que ou operador ou fabricante possam tomar as devidas ações corretivas.

4.3 Padrões de Falhas Ocorridas no Interior de Aeronaves Regionais

Todo problema vivenciado em uma aeronave e detectado, seja por meios visual ou por meio de instrumentos indicadores de panes, é devidamente anotado no livro de bordo (do inglês *log book*) da aeronave. Dependendo da configuração, tal livro pode variar desde um livro em papel, como ainda ser um registro eletrônico em caso de aeronaves mais modernas.

Porém uma vez que tal registro de evento é efetuado pela tripulação ou ainda pelo pessoal de apoio, uma ação para o mesmo deve ser tomada para que o problema seja sanado.

De acordo com as normas vigentes, é de responsabilidade do proprietário ou de quem opera uma aeronave de mantê-la em condições de aeronavegabilidade continuada, incluindo todos os requerimentos necessários para tal. Por sua vez, o mecânico com as devidas qualificações é a pessoa autorizada a aprovar que uma aeronave possa retornar ao serviço e ainda o responsável por fazer o registro de manutenção efetuada na aeronave. Uma aeronave, ao ser inspecionada em sinal de defeito, pode ter instrumentos e/ou equipamentos inoperantes, desde que os mesmos sejam permitidos por meio da lista mínima de equipamentos (*Master Minimum Equipment List – MMEL*), porém todas as discrepâncias devem ser reparadas por um mecânico qualificado em um determinado intervalo pré-estabelecido, conforme prescrito nas normas vigentes.

Os registros anotados no livro de bordo devem conter uma descrição detalhada do trabalho realizado, data da realização do serviço de manutenção, bem como assinatura, número do certificado do mecânico responsável pelo serviço de manutenção da aeronave. Cada país possui uma legislação específica para este tipo de caso, porém o que ocorre na prática é que vários países celebram acordos bilaterais de cooperação, com o intuito de facilitar o entendimento do regulamento, bem como uma uniformização das normas vigentes entre os países.

No caso do Brasil quem regula a aviação comercial é a ANAC – Agência Nacional de Aviação Civil. Para o caso de manutenção, as informações necessárias são especificadas no RBHA (Regulamento Brasileiro de Homologação Aeronáutica) número 91, subparte E (Manutenção, Manutenção Preventiva, Modificações e Reparos), seção 91.417 e ainda o RBHA número 121, subparte T (operações de voo), seção 121.563 e subparte V (relatórios e registros), seção 121.705 (relatório sumário de interrupção mecânica). Nos Estados Unidos, a aviação civil é regulamentada pelo FAA – Federal Aviation Authority, que por sua vez tem sua legislação análoga, o FAR (Federal Aviation Regulation).

Embora os operadores ou proprietários de aeronaves possam se sentir na obrigação de fornecer dados além daqueles listados no regulamento, as informações que um registro devem conter são os que seguem abaixo:

1. o fabricante, o modelo e o número de série da aeronave, motor ou hélice;
2. a matrícula da aeronave;
3. o nome do operador;

4. a data em que a falha, mau funcionamento ou defeito foi descoberto;
5. o estágio da operação no solo ou em voo em que a falha, mau funcionamento ou defeito foi descoberto;
6. a natureza da falha, mau funcionamento ou defeito;
7. o código aplicável do “*Joint Aircraft System/Component*” (Código de 4 números no formato XXYY onde XX são os dígitos referentes ao sistema e YY uma referência ao subsistema. Tal tabela compartilha um grande grau de comunalidade com a tabela semelhante da ATA e é largamente usada por toda indústria aeronáutica)
8. os ciclos totais, se aplicável, e as horas totais da aeronave, motor, hélice ou componente;
9. o fabricante, o número de parte do fabricante, o nome da parte, o número de série e o local do componente que falhou, funcionou mal ou apresentou defeito, se aplicável;
10. o fabricante, o número de parte do fabricante, o nome de parte, o número de série e o local da peça que falhou, funcionou mal ou apresentou defeito, se aplicável;
11. as precauções ou ações de emergência tomadas;
12. outras informações necessárias para análise mais completa da causa da falha, mau funcionamento ou defeito, incluindo as informações disponíveis referentes à designação de tipo de grandes componentes e o tempo desde a última manutenção, revisão, reparo ou inspeção;
13. uma identificação única da ocorrência, em forma aceitável pela autoridade regulamentadora local.

A **Tabela 4.2** mostra um exemplo do que seria um registro do livro de bordo da empresa fictícia *Airlines Pantaneira*:

LIVRO DE BORDO – REGISTRO DE FALHA			
Aeronave:	Tuiuiú	Código ATA	38-10
Matrícula:	PT-TUIU	Horas de voo da aeronave	2600
Nome do Operador:	<i>Airlines Pantaneira</i>	Número da peça	PC-ACQUA-1234 Série: 001
Data do Registro:	30/12/2006	Fabricante	Filtros Água Limpa
Fase do voo:	Cruzeiro	Problema	Água com cor de terra
Natureza da Falha:	Mau funcionamento	Ação	Fechada válvula do filtro de água

Tabela 4.2 – Livro de Bordo - Exemplo de Registro de Falha

Entende-se pelo interior de aeronaves toda a região da cabine de passageiros e ainda os respectivos anexos tais como lavatórios, *galleys* (cozinha para o preparo de alimentos), cadeiras dos comissários de bordo e ainda dos passageiros, maleiros para o armazenamento da bagagem de mão dos tripulantes ou dos passageiros, painéis de pisos, sistemas de suporte a vida tais como oxigênio de emergência, iluminação normal e de emergência, sistemas de prevenção e combate a incêndio, sistemas de evacuação de emergência da aeronave (escorregadores infláveis instalados nas portas de acesso), coletes e botes salva-vidas, etc.

Entre os operadores pode existir inclusive certo receio em vazamento de tais informações, uma vez que as mesmas se por um lado podem ser usadas de maneira benéfica na prevenção de futuros eventos ou mesmo acidentes, por um outro lado estas podem ser usadas de maneira prejudicial à imagem de uma empresa. Imagine por exemplo um cenário hipotético onde um operador qualquer tem acesso a informações de um outro operador. O operador que teve acesso a informações privilegiadas pode usá-las em campanhas publicitárias elucidando as suas eventuais vantagens e exaltando suas qualidades para que roube uma parcela de mercado de seu concorrente. Obviamente no mundo real este tipo de problema não acontece, pois as informações são mantidas sob sigilo, motivo pelo qual inclusive este trabalho não irá apresentar nomes nem mesmo modelos de aeronaves explicitamente, limitando-se apenas a dizer que se trata de aeronaves comerciais regionais para efeitos ilustrativos.

Após toda esta preocupação com o zelo pela informação, no próximo tópico será discutido em maiores detalhes como é o fluxo da informação. Na sequência será mencionado como é o contexto onde se situa, a ambientação dos operadores bem como as perdas referentes aos atrasos e finalmente como é feita a coleta destes dados para a posterior inclusão em um banco de dados seja ele na autoridade regulamentadora, no operador ou ainda no próprio fabricante da aeronave.

4.4 Fluxo da Informação

No dia a dia de um operador de uma aeronave, a quantidade de informações gerada é consideravelmente grande, não só limitando-se aos eventos reportados de problemas que ocorram como ainda eventos que são externamente induzidos ou mesmo eventos devido a manutenção feita de forma inadequada. A lista porém de tipos de eventos não se limitaria somente nestes três exemplos citados, sendo que se tem um grande leque de possibilidades que serão mostradas mais adiante. Embora exista um grande esforço na área de coleta de dados, vários são os problemas que ocorrem no dia a dia. Citando alguns problemas, mecânicos não treinados que por falta de tempo ou preparo ao preencher formulários não o

fazem da maneira mais adequada, erros de escrita ou ainda digitação, erros de classificação de peças que futuramente podem gerar uma visão equivocada de um sistema que não demandaria uma atenção especial por parte do fabricante, dificuldades de interpretação dos problemas pelas diferentes maneiras que um mecânico possa falar de uma determinada causa (na prática seria o mesmo que falar que *o copo está metade cheio, ou o copo estar metade vazio*), envio tardio das informações por parte do operador para os fabricantes (somado ainda ao tempo necessário para interpretação e análise e posterior solução) levando a isto a um tempo de reação muitas vezes demasiadamente longo, falta de conscientização do pessoal responsável de que tais informações são de grande importância para outras áreas correlatas (engenharia de produto, engenharia de produção, logística e comercial, controle de estoques, etc.), entre outras.

Basicamente quando um evento é gerado até o momento de seu fechamento, pode-se dizer de maneira sucinta que o mesmo passa por quatro estágios principais. O fluxograma mostrado na **Figura 4.1** mostra como ocorre tal processo:

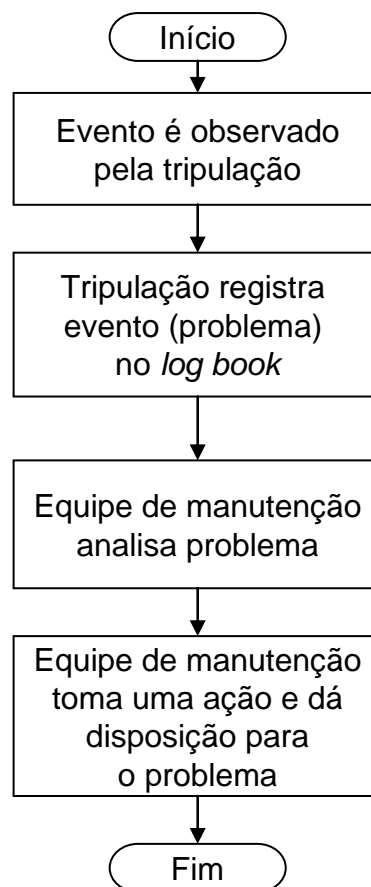


Figura 4.1 – Ciclo de Abertura e Fechamento de um Evento no Livro de Bordo

Logo que alguma anomalia é detectada na aeronave, faz parte das responsabilidades da tripulação a análise de tal anomalia. Se tal anomalia for considerada como um evento passível de entrar no livro de bordo, então o mesmo deve ser registrado pelo tripulante responsável (por exemplo o piloto ou ainda o chefe dos comissários de bordo). Os eventos por sua vez podem acontecer em qualquer etapa do voo, seja após a aeronave deixar o portão de embarque dos passageiros, taxiamento, decolagem, cruzeiro, aterrisagem ou ao chegar ao aeroporto de destino. Como as diferentes fases do voo envolvem diferentes complexidades, é de suma importância que tais registros sejam os mais detalhados possíveis, levando-se inclusive em consideração esta informação crucial que seria qual fase do voo o evento foi observado pela tripulação.

Tamanho é o impacto destes eventos na operação de uma aeronave e uma vez que tais eventos estão relacionados diretamente com a despachabilidade da mesma, as autoridades regulamentadoras mantêm um rigoroso controle sobre os mesmos, visando com isto o perfeito funcionamento do setor. Logo ganha o passageiro que pode contar com um serviço de qualidade e ainda a pontualidade, ganha o operador pois o mesmo é forçado a sempre melhorar seu processo e finalmente ganha o país por apresentar um serviço de transporte aéreo com qualidade e segurança.

4.5 Pré-Processamento dos Registros através de Mineração de Textos

Conforme explicado no nos itens anteriores, foi mostrado como é formado um banco de dados, o fluxo de informações, normas vigentes, entre outros aspectos relevantes. Sendo assim para o presente trabalho, foi reunido um banco de dados de registros coletados de livros de bordo de aeronaves, que foi submetido a mineração de textos, logo ocorreu a extração de informação destes documentos (registros) através da *numerização* dos mesmos. Dentre as principais características utilizadas para a mineração de textos, destacam-se:

- a) A preparação dos registros a serem analisados começa com a escolha do banco de dados. É possível a entrada de registros por meio de uma conexão em um banco de dados externo, um arquivo qualquer ou ainda importar dos registros diretamente em uma planilha;
- b) Escolha do idioma a ser utilizado para o agrupamento de palavras com raiz semelhante (*stemming*). Dentre os idiomas suportados, foi escolhido para a modelagem do problema a língua inglesa, uma vez que a maioria dos registros encontrados no banco de dados em análise ser constituído por registros nesta língua. Vale ressaltar que

existem pacotes *open source* com outras línguas, inclusive a língua portuguesa (BOULTON, 2002; ORENGO, 2001).

- c) Escolha de filtros onde é possível definir o tamanho mínimo e máximo das palavras e palavras indexadas, número mínimo de vogais, número máximo de consoantes consecutivas, número máximo de vogais consecutivas, número máximo de caracteres iguais e consecutivos, número máximo de sinais de pontuação consecutivos e porcentagem mínima e máxima de registros onde uma palavra ocorra. Tais recursos são muito úteis e podem inclusive serem utilizados como uma espécie de filtro *implícito*, uma vez que pode-se excluir erros de digitação (por exemplo um descritor não irá conter quatro vogais ou quatro consoantes consecutivas por exemplo, ou ainda não terá um número seguido por uma determinada sequência de consoantes e assim sucessivamente)
- d) Escolha de caracteres válidos para o início de uma palavra, para a constituição de uma palavra e ainda para o final de uma palavra. Dentre a lista de caracteres válidos, foram escolhidos os caracteres válidos na língua inglesa (neste caso excluindo qualquer registro oriundo de uma outra língua, por exemplo espanhol, polonês, italiano, etc. – estes por sua vez por apresentarem caracteres acentuados e não válidos para a utilização no presente trabalho)
- e) Definição de listas de palavras a serem incluídas, *stop words*, sinônimos e palavras múltiplas (frases). Neste aspecto é possível a retirada de palavras que não seriam bons descritores tais como artigos, preposições, entre outros já explicados no **Capítulo 2**. Com isto tem-se ainda mais uma opção de refinamento antes do início da mineração de textos propriamente dita.

Para o pré-processamento do banco de dados e sua respectiva modelagem, foram feitas algumas escolhas de parâmetros para a mineração de textos, com o intuito de alcançar um desempenho e resultados otimizados com o contexto aeronáutico, ou seja, pré-processamento de registros em texto oriundos de falhas reportadas e originárias de componentes relacionados ao interior de aeronaves regionais.

Valendo-se das várias opções disponíveis, cada uma das etapas anteriores a utilização da mineração de textos foi analisada e devidamente configurada, com a expectativa de que os registros após a mineração de textos pudessem ser condizentes com o conteúdo originado dos mesmos (consequentemente obtendo uma matriz onde tem-se várias colunas com *descritores* precisos do texto original dos registros analisados, estes representados por sua vez nas linhas da matriz formada – esta ideia é mostrada na **Figura 2.1** do **Capítulo 2**).

Várias são as formas de acesso aos dados necessários para a modelagem de um problema. De acordo com Oard (1996) *apud* Haykin (1999) eles podem ser classificados através do processo envolvido da geração dos dados, quais informações são desejadas destes dados gerados e finalmente que forma se encontra tais informações, conforme **Tabela 4.3**:

Processo	Informação	Origem
Informações Filtradas	Estável e Específica	Dinâmica e Não Estruturada
Informações Recuperadas	Dinâmica e Específica	Estável e Não Estruturada
Acesso em Banco de Dados	Dinâmica e Específica	Estável e Estruturada
Extração de Informação	Específica	Não Estruturada
Alertas	Estável e Específica	Dinâmica
Procuras	Extensa e Vasta	Não Específica
Entretenimento	Não Específica	Não Específica

Tabela 4.3 – Formas de Procura de Informação

Nesta modelagem pode-se dizer que a extração da informação do banco de dados utiliza-se das técnicas acima mencionadas, porém com exceção de processos referentes a procuras em geram e ainda entretenimento.

Quanto aos outros processos mencionados, todos podem ser de certa forma aplicáveis a esta modelagem, uma vez que trata-se de acesso em banco de dados de registros de livros de bordo de aeronave, que de certa forma são filtradas sob certas condições e ainda parte das informações estão estruturadas e estáveis (uma vez que se trata de dados históricos – caso fosse um sistema de análise em tempo real as informações seriam consideradas dinâmicas, porém não é este o problema em questão) e finalmente onde parte das informações tem origem não estruturada, ou seja, na forma de relatos descritivos do problema e ação reportada (que será submetido ao pré-processamento via mineração de textos).

Após o entendimento de como fazer a modelagem do problema e conseqüentemente de como iniciar o pré-processamento do banco de dados levantado, iniciou-se a coleta inicial dos registros do banco de dados, que corresponde a duas variáveis descritivas (uma coluna onde encontra-se o *problema* reportado e outra coluna onde encontra-se a *ação* tomada), ou seja, duas colunas do banco de dados bruto, conforme foi mostrado no **Capítulo 1 (Tabela 1.1)**.

A seguir foi necessário a escolha de outras *restrições*, tais como o idioma a ser utilizado para o *stemming* (encontrar o radical das palavras). Foi então escolhida a língua inglesa, uma vez que os registros encontram-se escritos em tal idioma. Valendo-se desta vantagem, outros filtros foram escolhidos, tais como os caracteres considerados como válidos para a mineração de textos. Uma facilidade neste caso é que a língua inglesa não possui

caracteres grafados tais como por exemplo acentos, cedilha, trema, etc. A **Tabela 4.4** mostra o conjunto de caracteres utilizados como sendo válidos para o pré-processamento dos registros:

Posição na Palavra	Conjunto de Caracteres Válidos
Para formação das palavras	-abcdefghijklmnopqrstuvwxyz
Para início das palavras	abcdefghijklmnopqrstuvwxyz
Para término das palavras	abcdefghijklmnopqrstuvwxyz

Tabela 4.4 – Conjunto de Caracteres Válidos

Note que é possível a delimitação de diferentes critérios para os caracteres válidos, dependendo ainda da sua posição relativa na palavra. Como pode-se verificar, para a formação das palavras ainda foi incluído o hífen, caso possa existir palavras do tipo compostas. Assim sendo, a posição na palavra corresponde ao início e fim das mesmas – no caso dos caracteres que não atendem estas restrições, entende-se que são qualquer um que não satisfaça as condições de caracteres inicial e final respectivamente.

Ainda quanto aos filtros existentes, optou-se pelo tamanho dos descritores, em termos do número de caracteres de cada um destes. Imagine que assim é possível excluir termos, siglas, erros de digitação, entre outros com tais opções. A **Tabela 4.5** mostra como foi feita a escolha de tais restrições em função do número de caracteres e combinações deles para validar um descritor:

Condição	Número de caracteres válidos
Tamanho mínimo da palavra	3
Tamanho máximo da palavra	25
Número mínimo de vogais na palavra	1
Tamanho mínimo do descritor	3
Número máximo de consoantes consecutivas	5
Número máximo de vogais consecutivas	4
Número máximo de caracteres iguais e consecutivos	2
Número máximo de caracteres de pontuação consecutivos	1
Porcentagem mínima de registros onde a palavra ocorre	3 %
Porcentagem máxima de registros onde a palavra ocorre	100 %

Tabela 4.5 – Condição dos Caracteres Válidos

Tais filtros mostrados na **Tabela 4.5** mostram de forma clara como podem ser úteis antes mesmo da execução da mineração de textos. Pense em erros de digitação tais como “*cofffee*” (palavra café grafada com três “F” – a grafia correta possui somente dois “F”). Tal palavra poderia ser contabilizada erroneamente como sendo um descritor, porém somente com a utilização de um dos filtros mencionados acima, é possível resguardar-se de tais

problemas. Neste exemplo, o filtro *Número máximo de caracteres iguais e consecutivos* consegue evitar este problema. Porém algumas siglas ou ainda jargões do ramo aeronáutico podem-se valer de algumas formas de grafia que por sua vez entrariam em algum tipo de filtro ou ainda algum tipo de restrição. Logo um outro recurso empregado antes do pré-processamento foi ainda uma lista de *sinônimos* e outra lista de *palavras-frase* (estes sendo contados como uma entidade única. Por exemplo imagine que é conhecido a priori que os termos *coffee* e *coffee maker* – como se trata do mesmo assunto (café e cafeteira) a análise pode ser configurada para que estes dois descritores e com isto obter uma contagem única para os mesmos).

Finalmente dentre as várias delimitações possíveis, existe a opção de utilização de dicionários específicos para o problema em pesquisa, ou seja, o contexto aeronáutico. A **Tabela 4.6** mostra um exemplo de alguns dos sinônimos empregados durante a fase preparatória da mineração de textos.

Raiz	Sinônimos	Raiz	Sinônimos
adjust	readjusted, repositioned, repositioned	latch	latch
aircraft	acft, airplane	light	lt, lamp, lights, ligh, ligt, lite
attach	resecure, secure, remove, re-secure, re-secured, secu	maker	makr
attendant	attd	message	msg
battery	batt, elpu	operational	op
bend	bent	overhead	ovhd
cart	trolley	passenger	pax
category	cat	power	pwr, pwer
change	chqd	recline	recl, reqd, requ
check	ck, chk, ckd	seam	sean
clear	clean, clear	seat	saet
coffee	coff	service	sv, svcd, svcs
emergency	emer	serviceable	svc
fixed	mel, reworked	stay	tay
flush	flus	tank	tanl
forward	fwd, fwd	valve	valv
hinge	hing	waste	wast, wate
hose	tube, tubo		

Tabela 4.6 – Lista de Sinônimos

Na lista de sinônimos da **Tabela 4.6** ainda foi feita a inclusão de alguns casos comuns de erros de digitação observados antes mesmo do pré-processamento, ou seja, o módulo de mineração de textos ao invés de tratá-los como casos isolados, irá contabilizar tais ocorrências como sendo na verdade descritores dos documentos.

O resultado da vetorização dos registros e de seus textos descritivos de problema e ação reportadas pode ser visualizado na **Tabela 4.7**. Embora cada registro possa variar no número de palavras que o constitui e ainda o número de descritores necessários, a matriz final

de descritores levará em consideração todos os descritores necessários para descrever cada um dos registros. Para um determinado registro que um descritor não exista, o descritor em questão será nulo (ou seja, tal descritor não *descreve* o determinado registro). Isto é importante para que a matriz final tenha uma dimensão $m \times n$ onde m seja igual ao número de registros analisados e n seja igual ao número de descritores utilizados.

Documento	Tamanho	Número de Palavras	Descritores
1	6	6	galley drain clog clear galley drain
2	13	13	cabin hardwar btw seat shear found hardwar instal repair armrest function normal releas
3	10	10	passeng door ceil shatter bulb clear glass cabin ceil place
4	6	6	lach place attach screw handl door
5	55	4	servic spill clear spill
6	95	9	lavatori door broken lock mechan lubric lock mechan check
7	68	8	pilot copilot life preserv miss replac life preserv
8	68	8	seat belt miss replac seat belt power aircraft
9	27	4	clog water pipe repair
10	112	7	passeng plug lavatori lavatori repair lavatori equip
11	78	5	broken tray reconnect tray check
12	79	7	manual releas miss replac miss jump seat
13	63	5	galley lavatori sink drain clog
14	92	9	attach lach galley upper miss place attach lach requir
15	70	3	captain request place
16	116	8	player volum inaud servic repair check player attach
17	106	7	water system confus discuss captain discuss water
18	115	9	water replac water wast system control drain replac hennessi
19	97	9	tray broken attach tray onboard problem lavatori smoke detector
...
...
...
15751	54	4	seat doesnt upright adjust
15752	55	3	seat mechan adjust
15753	37	2	seat repair
15754	70	3	seat cabl reattach
15755	50	3	seat cabl refit
15756	58	4	seat without button adjust
15757	73	5	seat fulli upright posit adjust
15758	48	6	passeng seat cover cabin servic advis
15759	52	3	seat adjust check
15760	54	5	seat upright posit seat adjust

Tabela 4.7 – Documentos Analisados

Após o pré-processamento, para se ter ideia da relação entre os descritores gerados bem como a frequência de tais palavras nos registros, foi feito o gráfico da **Figura 4.2** que mostra exatamente esta relação:




Figura 4.2 – Descritores e Frequência Absoluta nos Registros

Do banco de dados original de 15760 registros conforme mostrado na **Tabela 4.1**, os 88 descritores foram capazes de descrever 99,24% dos registros, ou seja, 15640 registros. Apenas 0,76% dos registros neste caso ficaram de fora. A análise poderia ser refeita com outras opções de mineração de textos para que fosse possível atingir índices ainda maiores, porém este percentual é muito mais do que aceitável e a quantidade de registros a ser ignorada neste caso é desprezível em comparação com o tamanho da amostra do banco de dados considerado. Ainda em termos de otimização, poderia aplicar-se a técnica de DVS como já mencionado no **Capítulo 2** para a redução do número de descritores através da redução do espaço dimensional da matriz, porém pela complexidade desta técnica e ainda pelo tamanho relativo do banco de dados não ser demasiadamente grande, a mesma não foi utilizada uma vez que o ganho em tempo de processamento seria desprezível e ainda poderia introduzir ruídos de processamento (BRZEZINSKI, 2000). Sem a utilização de técnicas de otimização, foi gasto aproximadamente apenas 3 minutos em um computador Pentium® Centrino Duo de 1,6GHz com 2GB de RAM.

Na sequência, a **Tabela 4.8** mostra a contagem de cada um dos descritores para o universo de documentos em análise e ainda o número de vezes que um descritor em questão aparece em um determinado registro. Isto é útil para posteriormente calcular-se a respectiva frequência dos descritores em cada documento, seja ela frequência binária, frequência log ou

ainda a frequência inversa de documentos. É ainda mostrada a forma raiz de cada descritor (obtida através da técnica de *stemming* já explicada no *Capítulo 2*).

Descritor	Frequência	Número de Documentos	Raiz	Descritor	Frequência	Número de Documentos	Raiz
actuat	158	150	actuat	handset	6	6	handset
adapt	5	3	adapt	heat	116	94	heat
adjust	3285	2886	adjust	hydrolock	312	295	hydrolock
armrest	590	353	armrest	insulation	5	4	insul
ashtray	1	1	ashtray	interphone	30	23	interphon
attach	2513	2326	attach	knob	41	27	knob
attend	1031	805	attend	lach	1382	928	lach
backlight	3	3	backlight	lavatory	4095	2601	lavatori
ballast	68	62	ballast	leak	507	383	leak
belt	488	326	belt	mask	198	133	mask
blanket	1	1	blanket	mast	98	79	mast
broken	1892	1823	broken	megaphon	68	48	megaphon
bumper	11	9	bumper	melted	17	17	melt
button	596	510	button	missing	937	859	miss
cabl	891	812	cabl	motor	7	7	motor
cartridge	5	5	cartridg	mount	58	43	mount
check	6125	5731	check	nozzl	7	6	nozzl
clear	1895	1793	clear	observ	56	36	observ
clog	142	132	clog	observer seat	17	16	observer seat
close	725	671	close	obstruct	25	24	obstruct
coffee maker	1137	881	coffee maker	outlet	17	15	outlet
cover	841	582	cover	oven	40	22	oven
curtain	143	117	curtain	overhead bin	579	422	overhead bin
cushion	125	99	cushion	oxygen	124	94	oxygen
dimmer	2	2	dimmer	passenger	929	826	passeng
discharge	3	2	discharg	passenger seat	61	56	passenger seat
disconnect	65	63	disconnect	pipe	9	9	pipe
disinfect	12	10	disinfect	placard	507	487	placard
doghouse	16	16	doghous	plug	98	85	plug
door	1350	942	door	posit	699	671	posit
drain	744	500	drain	relamp	1060	1048	relamp
electr	24	24	electr	replac	2751	2644	replac
emergency light	47	36	emergency light	requir	811	804	requir
escutcheon	29	29	escutcheon	reset	666	639	reset
extinguish	63	56	extinguish	seat	8192	5277	seat
faucet	325	217	faucet	sensor	346	304	sensor
firex	61	39	firex	servic	2425	2132	servic
flashlight	117	65	flashlight	sink	702	489	sink
flight attendant	544	457	flight attendant	system	857	709	system
flush	979	796	flush	tighten	156	153	tighten
frozen	1194	1049	frozen	tray	3215	1962	tray
galley	1768	1447	galley	upright	669	653	upright
halogen	2	1	halogen	wast	823	666	wast
halon	9	6	halon	water	2803	1645	water

Tabela 4.8 – Descritores, Frequência, Número de Documentos e Raiz

Finalmente tem-se uma matriz conforme descrito anteriormente no formato $m \times n$, onde cada descritor recebe um determinado valor em relação ao respectivo registro, e ainda relacionado a qual frequência foi escolhida para quantificar os descritores. A **Tabela 4.9** mostra como é a matriz (resultado final) após aplicada a técnica de mineração de textos. Vale ainda reforçar que cada coluna corresponde a um descritor e cada linha corresponde a um registro do banco de dados original:

	actuat		adapt	adjust	armrest		seat	servic		system	tighten		wast	water
1	0.000	...	0.000	0.000	0.000	...	0.000	0.000	...	0.000	0.000	...	0.000	0.000
2	0.000	...	0.000	0.000	3.799	...	1.094	0.000	...	0.000	0.000	...	0.000	0.000
3	0.000	...	0.000	0.000	0.000	...	0.000	0.000	...	0.000	0.000	...	0.000	0.000
4	0.000	...	0.000	0.000	0.000	...	0.000	0.000	...	0.000	0.000	...	0.000	0.000
5	0.000	...	0.000	0.000	0.000	...	0.000	2.000	...	0.000	0.000	...	0.000	0.000
6	0.000	...	0.000	0.000	0.000	...	0.000	0.000	...	0.000	0.000	...	0.000	0.000
7	0.000	...	0.000	0.000	0.000	...	0.000	0.000	...	0.000	0.000	...	0.000	0.000
8	0.000	...	0.000	0.000	0.000	...	1.853	0.000	...	0.000	0.000	...	0.000	0.000
9	0.000	...	0.000	0.000	0.000	...	0.000	0.000	...	0.000	0.000	...	0.000	2.260
10	0.000	...	0.000	0.000	0.000	...	0.000	0.000	...	0.000	0.000	...	0.000	0.000
...
15750	0.000	...	0.000	1.698	0.000	...	1.094	0.000	...	0.000	0.000	...	0.000	0.000
15751	0.000	...	0.000	1.698	0.000	...	1.094	0.000	...	0.000	0.000	...	0.000	0.000
15752	0.000	...	0.000	0.000	0.000	...	1.094	0.000	...	0.000	0.000	...	0.000	0.000
15753	0.000	...	0.000	0.000	0.000	...	1.094	0.000	...	0.000	0.000	...	0.000	0.000
15754	0.000	...	0.000	0.000	0.000	...	1.094	0.000	...	0.000	0.000	...	0.000	0.000
15755	0.000	...	0.000	1.698	0.000	...	1.094	0.000	...	0.000	0.000	...	0.000	0.000
15756	0.000	...	0.000	1.698	0.000	...	1.094	0.000	...	0.000	0.000	...	0.000	0.000
15757	0.000	...	0.000	0.000	0.000	...	1.094	2.000	...	0.000	0.000	...	0.000	0.000
15758	0.000	...	0.000	1.698	0.000	...	1.094	0.000	...	0.000	0.000	...	0.000	0.000
15759	0.000	...	0.000	1.698	0.000	...	1.853	0.000	...	0.000	0.000	...	0.000	0.000
15760	0.000	...	0.000	0.000	0.000	...	0.000	0.000	...	0.000	0.000	...	0.000	0.000

Tabela 4.9 – Banco de Dados Após Mineração de Textos

Em termos dimensionais, a matriz formada após a mineração de textos tem a dimensão de 15760 linhas (onde cada linha representa um registro do banco de dados) por 88 colunas (onde cada coluna representa um descritor). Tal matriz será emparelhada com as outras variáveis de entrada e saída do banco de dados, para que posteriormente possa ser apresentada a RNA. Tal procedimento será apresentado em maiores detalhes no **item 4.6 – Classificação Neural de Registros de Falhas**. Os registros em que todos os descritores apresentaram frequência igual a zero não serão considerados para o modelamento da RNA, ou seja, o número de linhas da matriz que efetivamente será utilizado para modelagem será 15640 registros.

4.6 Classificação Neural de Registros de Falhas

Dando prosseguimento na análise dos resultados, viu-se como foi feito o pré-processamento dos registros cujas variáveis *problema* e *ação* reportados na forma de texto não estruturado foram modelados e processados, de forma que os mesmos fossem armazenados em uma forma vetorial e estruturada, de acordo com a técnica explicada no **Capítulo 2**. A partir desta tabela onde cada linha corresponde a um documento e cada coluna consiste em um descritor (palavra chave que descreve um determinado documento) e somado a outras colunas que correspondem a outras variáveis qualitativas de um determinado registro, será construída a entrada e saída de valores para a RNA a ser modelada, treinada e validada.

Do banco de dados bruto formado conforme mostrado na **Tabela 1.1** no **Capítulo 1**, a nova matriz gerada após a mineração de textos tem o seguinte arranjo de colunas, com destaque nas variáveis “descritoras” de 3 à 90, conforme **Tabela 4.10** a seguir:

Variáveis de Entrada	Descrição
1-2	Ano e Mês do Registro
3-90	Problema e Ação Reportado (uma coluna por cada descritor)
91	Capítulo ATA da peça
92	Sub-Capítulo ATA da peça
Variáveis de Saída	Descrição
93	Houve interrupção? (sim/não)
94	Tipo de Interrupção: <ul style="list-style-type: none"> • atraso (<i>delay</i>) • cancelamento (<i>cancellation</i>) • retorno da pista de decolagem (<i>return from runway</i>)
95	Concordância do fabricante em relação à falha reportada
96	Comentário do fabricante em relação à falha reportada

Tabela 4.10 – Variáveis Após Mineração de Textos

A classificação neural de registros de falhas foi realizada utilizando algumas opções de pré-processamento e pós-processamento, seleção e codificação de variáveis (transformação de variáveis nominais em numéricas), escalonamento, normalização (padronização).

Neste trabalho foi tomado o cuidado de verificar cada etapa do processo de modelagem da RNA, ou seja foi possível ter controle de todas as etapas e parâmetros para a modelagem da rede neural e com isto ter uma melhor visão de tais parâmetros utilizados. Com isto foi possível para a presente modelagem ajustar e escolher diversos fatores, tais como:

- Focar a modelagem em um tipo particular de rede neural (MLP, RBF, etc.);

- Escolher a taxa de aprendizado (por exemplo é possível escolher entre uma taxa de aprendizado pequena que irá conduzir a uma velocidade de aprendizado lenta e conseqüentemente um acerto maior ou ainda uma taxa de aprendizado grande que irá conduzir a uma velocidade de aprendizado rápido porém desta vez o acerto será menor);
- Quantos neurônios terá determinada camada oculta e quais os números de camadas ocultas
- Qual o critério de parada do treinamento;
- Qual será o conjunto e proporção usado para treinamento, validação e teste da rede neural;
- Número de épocas de treinamento (época significa um passo por todo o conjunto de treinamento, seguido pelo teste do conjunto de verificação), etc.

Logo para iniciar a modelagem da RNA a representar o problema, verificou-se no banco de dados qual o papel de cada variável, ou seja, quais variáveis puderam ser classificadas como sendo de entrada (independentes) originadas do pré-processamento através da mineração de textos, assim como as variáveis de saída (dependentes). Conseqüentemente, as variáveis de saída consistem em dizer se o evento descrito pelas suas respectivas variáveis de entrada acabou por gerar ou não uma interrupção na aeronave (entende-se por interrupção neste caso como já explicado anteriormente no *item 4.3* uma situação de atraso, cancelamento do voo agendado, ou ainda retorno da pista de decolagem), se a interrupção foi causada realmente por um problema ligado ao sistema reportado e finalmente qual o motivo que levou ao problema reportado. Como a variabilidade nas saídas era muito grande, tomou-se o cuidado de antes de apresentar os dados para a rede neural ser treinada, de realizar um trabalho de pré-codificação das saídas através de reduzir ao máximo o número de saídas existentes.

Conforme mostrado na *Tabela 4.10*, o banco de dados e os respectivos registros são constituídos em sua totalidade de variáveis categóricas, ou seja, cada uma das variáveis pode ser constituída de dois ou mais estados (por exemplo: Sim ou Não; Quente/Morno/Frio; e assim sucessivamente). Logo tal problema pode ser modelado por uma rede neural do tipo classificatória, ou seja, ela irá preocupar-se em encontrar determinados padrões inerentes dos registros oriundos do banco de dados e com isto realizar o treinamento da mesma baseado em tais características destes padrões. Embora o software utilizado para a modelagem da rede neural possua recursos de pré-processamento das variáveis nominais, por exemplo nos casos onde uma variável nominal possua mais do que dois casos, foi feito o desmembramento das

mesmas, de maneira que cada entrada na rede neural não tenha mais do que dois estados distintos, assim garantindo que o banco de dados de registros possa inclusive ser utilizado de forma fácil até mesmo em um outro pacote de software de modelagem de redes neurais. Com esta ação evita-se problemas de uma falsa ordem de importância dentro de uma variável, em outras palavras para o exemplo dado do tipo de interrupção da peça não existe um motivo mais importante que o outro. Exemplificando o que foi feito com tais variáveis, pode-se tomar como base a variável de número 94 apresentada na **Tabela 4.10**. Imagine que temos três tipos de estados para a interrupção (atraso, cancelamento ou retorno da pista de decolagem). Ao invés de se codificar as variáveis como *atraso = 1*, *cancelamento = 2*, e *retorno da pista de decolagem = 3*, desmembra-se esta variável que inicialmente encontrava-se em uma única coluna para três colunas, então tendo *atraso = (1-0-0)*, *cancelamento = (0-1-0)* e *retorno da pista de decolagem = (0-0-1)*.

Este trabalho de pré-codificação feito para as variáveis de entrada também foi feito para as variáveis de saída da rede neural. Porém para as variáveis de saída, como o banco de dados de registros apresentava uma grande variabilidade inicial, foi feito em adição a codificação das respostas conforme mostrado com o exemplo da variável de interrupção, a condensação do universo possível de respostas. Foi ainda levado em consideração casos de nenhuma falha encontrada (NFF – *No Fault Found*), devido a importância deste indicador, que pode significar entre várias causas possíveis por exemplo falta de treinamento adequados mecânicos (SÖDERHOLM, 2005).

O resultado da pré-codificação ou normalização realizada pode ser conferido a seguir conforme mostrado na **Tabela 4.11** para as variáveis de entrada:

Variáveis de Entrada	Descrição
1-88	Descritores originados no pré-processamento do problema e ação reportado através da Mineração de Textos
89-92	Modelo da aeronave (A, B, C e D)
93-97	Capítulo ATA da peça
98-119	Sub-Capítulo ATA da peça

Tabela 4.11 – Variáveis de Entrada da Rede Neural

O mesmo acontece no âmbito das variáveis de saída. De forma a facilitar a modelagem, um trabalho similar também é realizado com as respostas.

Para as variáveis de saída, o resultado da pré-codificação ou normalização realizada é mostrado na **Tabela 4.12**:

Variáveis de Saída		Descrição
120		Houve interrupção? (sim/não)
121		Interrupção = atraso (<i>delay</i>)
122		Interrupção = cancelamento (<i>cancellation</i>)
123		Interrupção = retorno da pista de decolagem (<i>return from runway</i>)
124		Concordância do fabricante em relação à falha reportada
Comentário do Fabricante		
125	CM01	Problema de fixação (<i>Attachment Problem</i>)
126	CM02	Problema de drenos (<i>Drain Problem</i>)
127	CM03	Falha elétrica (<i>Electrical Failure</i>)
128	CM04	Falha externamente induzida (<i>External Induced Failure</i>)
129	CM05	Falha em equipamentos da <i>Galley</i> tais como Cafeteira, Forno à Vapor, etc – porém não relacionadas à <i>Galley</i> - (<i>Galley Inserts Failure</i>)
130	CM06	Problemas de Aquecimento (<i>Heater Problem</i>)
131	CM07	Limpeza Inapropriada (<i>Improper Cleaning</i>)
132	CM08	Manuseio Inapropriado (<i>Improper Handling</i>)
133	CM09	Lubrificação Inapropriada (<i>Improper Lubrication</i>)
134	CM10	Manutenção Inapropriada (<i>Improper Maintenance</i>)
135	CM11	Serviços de Rotina Inapropriados (<i>Improper Servicing</i>)
136	CM12	Problemas de Fechos (<i>Latch Problems</i>)
137	CM13	Problemas <u>de</u> Travas (<i>Lock Problems</i>)
138	CM14	Falha mecânica em geral (<i>Mechanical Failure</i>)
139	CM15	NFE (Nenhuma Falha Encontrada) – NFF (<i>No Fault Found</i>)
140	CM16	Problema no mecanismo de reclino (<i>Recline Mechanism Problem</i>)
141	CM17	Checagem Rotineira (<i>Routine Check</i>)
142	CM18	Problema com Cinto de Segurança (<i>Seat Belt Problem</i>)
143	CM19	Peça gasta (<i>Wearout</i>)
144	CM20	Pesquisa de panes feita erroneamente (<i>Wrong Troubleshooting</i>)

Tabela 4.12 – Variáveis de Saída da Rede Neural

Logo conseguiu-se condensar um número razoável de variáveis para a modelagem, totalizando 119 variáveis de entrada e 25 variáveis de saída.

Este trabalho de pré-codificação com as variáveis de saída é mostrado através do gráfico na **Figura 4.3**. Com isto foi possível aplicar o mesmo tratamento empregado para as variáveis de entrada também nas variáveis de saída e ainda manter o número de respostas de saída finito e não extenso (pois caso este número de saídas fosse elevado, poderia inviabilizar o treinamento de uma rede neural).




Figura 4.3 – Participação das Respostas de Saída (Codificadas)

Como a modelagem consiste na classificação de eventos baseada na descrição do problema e ação e a respectiva categoria de resposta, optou por fazer uso da rede MLP (*Multilayer Perceptron*) por se tratar de uma rede estática e flexível para este tipo de problema.

Algumas outras considerações heurísticas importantes antes da modelagem da rede neural também foram observadas. De acordo com Haykin (1999), algumas regras heurísticas podem ser observadas para dar início ao modelamento de uma RNA conforme listado a seguir:

1. Atualização das taxas de erros para a retropropagação em modo estocástico (sequencial) ou em lote: Embora cada modo apresente suas vantagens e particularidades, por exemplo a atualização em lote é melhor pois apresenta os erros no final, enquanto que no modo estocástico apresenta ao fim de cada época de treinamento;
2. Maximização do conteúdo da informação: utilização de um conjunto de exemplos que maximizasse o erro de treinamento. Salientando que para esta modelagem utilizou-se cinco anos de dados históricos, logo foi possível uma aleatorização do banco de dados (*shuffle*), de forma que os exemplos apresentados durante a fase de treinamento entre uma época e outra refletissem uma grande generalização para a rede neural. É importante ainda abrir um parêntese pois mesmo que exista uma grande generalização de casos apresentada a RNA, alguns dos registros utilizados no treinamento podem ter sofrido de má interpretação por parte do informante e conseqüentemente *embutir* um “ponto fora da curva” atrapalhando a modelagem;

3. Normalização de entradas e saídas: cada variável a ser utilizada pode ser pré-processada para que não interfira durante a modelagem nos pesos das conexões sinápticas. Tal regra foi de certa forma alcançada pelo trabalho mencionado anteriormente onde normalizou-se e codificou-se as variáveis tanto de entrada como de saída;
4. Treinamento através de *dicas*: entende-se por *dicas* para o treinamento da rede neural exemplos que são considerados importantes pelo analista e que possam aumentar a riqueza da diversidade do banco de dados. Tal iniciativa é utilizada para adicionar e garantir aos registros uma maior variabilidade de casos, com isto garantindo a diversidade de registros na fase de treinamento;
5. Taxa de aprendizado: idealmente todos os neurônios deveriam *aprender* na mesma taxa de aprendizado. Porém segundo LeCun (1993) *apud* Haykin (1999) é conveniente utilizar valores menores para a taxa de aprendizado nas últimas camadas da rede, enquanto que as primeiras camadas valores maiores. Isto é devido que para um dado neurônio, a taxa de aprendizado deve ser inversamente proporcional a raiz quadrada das conexões sinápticas feitas para o determinado neurônio.

Em relação as frequências encontradas durante a fase de mineração de textos, foi feita uma normalização das mesmas de forma a facilitar o treinamento. Uma transformação binária foi utilizada, ou seja, caso a frequência fosse maior que zero, o respectivo descritor foi igualado a verdadeiro, enquanto que para frequência igual a zero o descritor foi igualado a falso. Como a transformação foi feita após o pré-processamento, não foi perdida a relevância do descritor nem no contexto do registro, nem como no contexto do conjunto de registros.

Então após todos estes cuidados, iniciou-se a modelagem da RNA. O primeiro passo com o banco de dados de 15760 registros foi a separação dos pacotes para treinamento, teste e validação. Utilizou-se a proporção clássica de 2:1:1 (ou seja, 50% dos registros foram utilizados para o treinamento, 25% para teste, e finalmente 25% para validação dos dados). Na fase de treino a rede neural é iniciada com os pesos entre as conexões sinápticas dos neurônios aleatoriamente (com base numa distribuição normal com média igual a zero e com desvio padrão igual a um). Logo em seguida, cada caso é apresentado a rede neural onde as entradas fazem excitar cada um dos neurônios (e as respectivas funções de ativação dos mesmos) Na fase de validação, os dados referentes as variáveis de entrada são apresentados a rede neural e com isto é obtida uma resposta – esta resposta é então comparada a resposta do banco de dados e caso as duas sejam iguais a rede neural disponibilizou uma resposta correta,

caso contrário é então contabilizado um erro que será utilizado para cálculo da taxa de acerto da rede neural. Finalmente, para o treinamento foi utilizado o algoritmo de *backpropagation* (BP).

A **Tabela 4.13** mostra os arranjos para as redes neurais a serem modeladas, bem como um sumário dos respectivos parâmetros de cada configuração e finalmente seus resultados:

Arranjo da rede neural (MLP)	119-33-25	119-43-25	119-53-25	119-63-25	119-73-25
Parâmetros					
Função de Ativação					
Camada 1 (entrada)	Hiperbólica	Hiperbólica	Hiperbólica	Hiperbólica	Hiperbólica
Camada 2 (oculta)	Hiperbólica	Hiperbólica	Hiperbólica	Hiperbólica	Hiperbólica
Camada 3 (saída)	Logística	Logística	Logística	Logística	Logística
Função de Classificação de Erro					
	EQM	EQM	EQM	EQM	EQM
Eficiência					
Treinamento	0.930196	0.934415	0.934543	0.937867	0.924827
Teste	0.925319	0.926854	0.934271	0.930179	0.937340
Validação	0.931202	0.933503	0.927621	0.923017	0.931969
Taxa de Erro					
Treinamento	0.166373	0.167903	0.167232	0.170275	0.174229
Teste	0.173939	0.176193	0.176450	0.180737	0.183264
Validação	0.172378	0.178355	0.179919	0.181283	0.182995
Algoritmo de Treinamento					
	BP	BP	BP	BP	BP
Épocas Treinadas					
	987	985	995	997	926

Tabela 4.13 – Resultados das RNAs

A escolha dos parâmetros não foi de forma arbitrária. Primeiramente variou-se o número de neurônios da camada oculta, de forma a verificar qual a influência deste parâmetro na taxa de acertos de cada RNA modelada. Verificou-se que este parâmetro não contribuiu de forma significativa para a taxa de acertos das redes. Por exemplo, a primeira coluna o arranjo 119-33-25 significa que é uma RNA com 119 entradas, 33 neurônios na camada oculta e finalmente 25 saídas.

Para o cálculo de erro entre o valor previsto pela rede neural e pelo valor original utilizado para o treinamento, foi utilizada a função de erro da soma do quadrado da diferença entre o valor previsto pelo valor real. Ainda que métodos de estimativa de erro baseados na máxima verossimilhança sejam recomendados para problemas de classificação, tal função é utilizada tanto em modelagens de problemas de classificação como também de regressão com grande robustez.

Para as funções de ativação dos neurônios, escolheu-se as funções hiperbólica para as camadas de entrada e a função logística para a camada de saída. A função de ativação hiperbólica foi escolhida pois encontra-se no intervalo $(-1;1)$, o mesmo intervalo onde as variáveis do banco de dados encontram-se normalizadas. A função logística por sua vez fora utilizada na última camada, pois é utilizada em conjunto com a função de erro para verificação do processo de treinamento. É importante lembrar que a função de soma quadrática do erro utilizada em conjunto com a função logística, ainda que não seja uma estimativa estatística como a função de erro baseada na entropia, ela apresenta uma taxa de treinamento mais rápida, o processo de treinamento é mais estável e finalmente ela pode atingir taxas de classificação mais altas.

Para a taxa de aprendizado, foi considerado um valor pequeno (0,001), com isto objetivando uma varredura detalhada e ainda uma lenta “convergência” ao ponto de mínimo na superfície de erro de resposta. Em adição a taxa de aprendizado escolhida, um momento de (0,3) foi escolhido de forma que fosse obtida uma velocidade de “convergência” satisfatória, em conjunto com um número de 500 épocas para o treinamento para cada uma das duas etapas, totalizando 1000 épocas. Segundo Haykin (1999), experimentos empíricos mostraram que quando a taxa de aprendizado tende a zero, o momento deve tender a um – o que produz uma velocidade de convergência. O contrário por sua vez é feito para que seja alcançado uma estabilidade de aprendizado da rede neural. Valores diferentes das relações citadas podem gerar efeitos indesejáveis, como uma oscilação do EQM durante o treinamento.

Para as condições de parada do treinamento, foi escolhida uma taxa de 0,05; que significa que a rede neural irá encerrar o treinamento quando a taxa de erro for menor que este valor. É importante destacar que no algoritmo de retropropagação de erro o critério de parada pode ou não ser alcançado, podendo-se também verificar a condição do erro através dos treinamentos entre diferentes épocas, ou seja, quando da degradação do mesmo que pode indicar situações de *over-fitting* ou *over-learning* (sobreaprendizado). Ainda caso tal taxa de erro não fosse alcançada, outro critério de parada seria o número de épocas informadas ao módulo de treinamento necessárias para a parada, que para este problema foi de 1000 épocas. Normalmente o que se observa é uma queda no erro no início do treinamento e em seguida uma estabilização do mesmo com o passar das épocas.

Verificou-se que o aumento do número de neurônios da camada oculta não influenciou muito nem na diminuição, nem no aumento da taxa de erro. A mesma permaneceu praticamente constante com os diferentes arranjos de camadas. Para este problema, pode-se utilizar a rede neural de configuração mais simples, pois dentre as treinadas, foi a que

apresentou a menor taxa de erro. O mesmo aconteceu com a eficiência das redes. Este parâmetro no caso de redes neurais empregadas para classificação de eventos mostra a eficiência por subgrupo utilizado em cada uma das fases (treinamento, seleção e finalmente validação). No caso dos valores de validação, este representa a proporção dos casos corretamente classificados dividido pelo número total de casos reservados para o fim de validação (em outras palavras, os casos que não foram apresentados durante a fase de treinamento).

A seguir no *Capítulo 5*, é feita uma breve conclusão sobre o presente trabalho, bem como algumas aspirações para trabalhos futuros.

5. Conclusão

5.1 Sobre o Modelo Proposto

O modelo proposto para o reconhecimento neural de padrões de texto em registros valeu-se de uma nova abordagem para encontrar relação entre variáveis de um banco de dados oriundo de interrupções em aeronaves comerciais regionais, uma vez que problemas semelhantes abordados na literatura somente trabalham com dados quantitativos, o que torna mais fácil a modelagem de uma rede neural.

Conceitualmente o presente modelo mostrou-se razoável, com uma taxa de acertos em torno de 93% quando verificado os resultados individuais por subgrupos na *Tabela 4.13* quando comparado aos registros utilizados para validação da rede neural e de forma automática. Isto de certa maneira é um grande avanço, pois normalmente tais registros quando analisados, demandam uma grande monta de tempo disponível por parte do time de analistas que seria responsável pela análise e geração de relatórios e ainda com taxas de acerto na ordem de 88%, sendo que o processo manual muitas vezes é suscetível aos erros. Uma vez que o sistema automatizado atingiu patamar comparável ao da análise manual, tal modelo proposto mostra-se promissor para aplicações práticas, obviamente com outras técnicas de otimização para que a taxa de erro de classificação possa ser diminuída para menos de 10% - com isto ultrapassando o valor encontrado quando se faz uma análise manual de um conjunto de registros.

Porém em termos práticos a utilização do modelo ainda requer cautela, uma vez que quando o modelo é analisado em termos das variáveis individualmente, algumas apresentam altos valores de erro de previsão. Isto foi detectado através da análise de sensibilidade das variáveis. Conseqüentemente a utilização do modelo em termos práticos seria como uma

ferramenta extra no arsenal do operador, porém ainda necessário a análise e palavra final do especialista em manutenção.

5.2 Proposição para Trabalhos Futuros

Através da utilização de outras técnicas em conjunto com as utilizadas na presente modelagem tais como Planejamento de Experimentos (*DOE – Design of Experiments*), Decomposição de Valores Singulares (DVS) ou ainda Análise de Componentes Principais (PCA) pode ser possível que os resultados sejam mais refinados dos que os encontrados no estágio atual da modelagem aqui realizada.

Pode ser possível também através dos registros encontrados e da análise de sensibilidade da RNA, verificar as variáveis que de certa maneira ao invés de adicionar informação ao modelo acabem por gerar ruídos no mesmo, conseqüentemente degradando a taxa de acerto da RNA.

Uma vez que um modelo deste esteja validado e com uma taxa de erros abaixo de 10%, pode ser considerado a sua utilização em conjunto com sistemas de pesquisas de pane em tempo real, como já é feito em alguns componentes de aeronaves (no caso do setor aeronáutico) ou ainda o uso análogo em outros setores de transporte. Em tal ajuste fino, poderia ainda ser agregado uma análise de severidade das mesmas, levando-se em conta graus de importância dos componentes (se são para suporte, equipamentos de emergência, entre outros) e com isto a possível alocação da mão de obra disponível para solução destes. Ainda no âmbito do *software* empregado, como já existem vários algoritmos disponíveis seria de fácil implementação um sistema de pré-processamento utilizando a mineração de textos e ainda a posterior resposta aos estímulos internos utilizando uma RNA.

Ainda não foi abordado no presente trabalho como seria a fase de realimentação do modelo com novos registros, pois este banco de dados compreendeu 5 anos de operação das aeronaves. É fato que quanto mais registros apresentados, mais diversidade disponível, logo mais robusto o modelo. A utilização de ferramentas *open source* tais como a Linguagem R para mineração de textos e algoritmos de redes neurais em uma outra linguagem qualquer daria ainda total independência ao programa de análise.

Tais tecnologias como amplamente mencionadas na literatura encontram-se ainda no seu estágio inicial, dando margem a imaginação e criatividade de onde possam ser aplicadas e sendo este trabalho apenas o início de um legado de pesquisa.

REFERÊNCIAS BIBLIOGRÁFICAS

Agência Nacional de Aviação Civil – ANAC. Disponível em <http://www.anac.gov.br/>. Capturado em 01/08/2009.

Air Transport Association of America – ATA. *Spec 2000 – Chapter 11 - Integrated Data Processing Materials Management*, Washington, DC, USA, 2009

AL-GARNI, A.Z.; JAMAL, A.; AHMAD, A.D.; AL-GARNI, A.M.; TOZAN, M. Neural network-based failure rate prediction for De Havilland Dash-8 Tires. *Engineering Applications of Artificial Intelligence*, v.19, p.681–691, 2006

BATYRSHIN, I.Z.; SHEREMETOV, L.B. Perception-based approach to time series data mining. *Applied Soft Computing*, v.8, p.1211-1221, 2008

BINEID, M.; FIELDING, J.P. Development of a civil aircraft dispatch reliability prediction methodology. *Aircraft Engineering and Aerospace Technology*, v.75, p.588-594, 2003.

BISHOP, C.M. *Neural Networks for Pattern Recognition*. New York: Oxford University Press, 1995. 1a ed., v.1, 477 p.

BOULTON, R. Snowball project. Disponível em <http://snowball.tartarus.org/index.php>. Acesso em 01/11/2009.

BRZEZINSKI, J.R. *Logistic Regression for Classification of Text Documents*. 2000. Dissertação de Pós-Doutorado. DePaul University, School of Computer Science, Telecommunications, and Information Systems, Chicago, IL, 2000.

CHIANG, D.; KEH, H.; HUANG, H.; CHYR, D. The Chinese text categorization system with association rule and category priority. *Expert Systems with Applications*, V.35, p.102-110, 2008.

FARRERO, J.M.C.; TARRÉS, L.G.; LOSILLA, C.B. Optimization of replacement stocks using a maintenance programme derived from reliability studies of production systems. *Industrial Management & Data Systems*, v.102/4, p.188-196, 2002.

FERNANDEZ, O.; WALMSLEY, R.; PETTY, D.J. A decision support maintenance system – Development and Implementation. *International Journal of Quality & Reliability Management*, v.20, No.8, p.965-979, 2003.

HANSSON, J.; BACKLUND, F.; LYCKE, L. Managing commitment: increasing the odds for successful implementation of TQM, TPM or RCM. *International Journal of Quality & Reliability Management*, v.20, No. 9, p.993-1008, 2002.

HAYKIN, S. *Neural networks – a comprehensive foundation*. Ontario, Canada: Prentice Hall International, 1999, 2a ed., v.1, 842 p.

KNOTTTS, R. M. H. Civil aircraft maintenance and support - Fault diagnosis from a business perspective. *Journal of Quality in Maintenance Engineering*, V.5, No. 4, p.335-347, 1999.

- KUMAR, U. D. New trends in aircraft reliability and maintenance measures. *Journal of Quality in Maintenance Engineering*, V.5, No.4, p.287-295, 1999.
- KURIEN, K.C.; SEKHON, G.S.; CHAWLA, O.P. Analysis of Aircraft Reliability Using Monte Carlo Simulation. *International Journal of Quality & Reliability Management*, V.10, No. 2, 1993
- LEITNER, F.; VALENCIA, A. A text-mining perspective on the requirements for electronically annotated abstracts. *Federation of European Biochemical Societes*, v.582, p.1178-1181, 2008.
- LUXHØJ, J.T. Trending of equipment inoperability for commercial aircraft. *Reliability Engineering and System Safety*, p.365-381, 1999.
- ORENGO, V.; HUYCK, C. A Stemming Algorithm for the Portuguese Language. *Eighth Symposium on String Processing and Information Retrieval*, Spire 2001, p.186, 2001.
- PRADO, H.A.; FERNEDA, E. Emerging technologies of text mining – techniques and applications. Hershey, PA: Information Science Reference – IGI Global, 2008. 1a. ed., v.1, 358 p.
- SARAC, A., *Daily operational aircraft maintenance routing problem*. 2000. Dissertação de Pós-Doutorado. University of Buffalo at New York, NY, 2000.
- SEKHON, G.S., RAJPAL, P.S., SHISHODIA, K.S. An artificial neural network for modeling reliability, availability, and maintainability of a repairable system. *Reliability Engineering and System Safety*, p.809-819, 2005.
- SHANKAR, G.; SAHANI, V. Reliability analysis of a maintenance network with repair and preventive maintenance. *International Journal of Quality & Reliability Management*. v.20, No. 2, p.268-280, 2003.
- SÖDERHOLM, P. A system view of the No Fault Found (NFF) phenomenon. *Reliability Engineering and System Safety*, V.92, p.1-14, 2005.
- TAN, S. An improved centroid classifier for text categorization. *Expert Systems with Applications*, v.35, p.279-285, 2008.
- US Bureau of Transportation – BTS. Disponível em <http://www.bts.gov/>. Capturado em 01/08/2009.
- WANG, W.M.; CHEUNG, C.F.; LEE, W.B.; KWOK, S.K. Mining knowledge from natural language texts using fuzzy associated concept mapping. *Information Processing and Management*, v.44, p.1707-1719, 2008.
- WILL, J.; BERTRAND, M.; FRANSOO, J.C. Operations management research methodologies using quantitative modeling. *International Journal of Operations & Production Management*. v.22, No. 2, p.241-264, 2002.
- WU, H.; LIU, Y.; DING, Y.; QIU, Y. Fault diagnosis expert system for modern commercial aircraft. *Aircraft Engineering and Aerospace Technology*, v.76, No. 4, p.398-403, 2004.

BIBLIOGRAFIA COMPLEMENTAR

AHMED, J.U. Modern approaches to product reliability improvement. *International Journal of Quality & Reliability Management*, v.13, No. 3, p.27-41, 1996.

Air Transport Association of America – ATA. *Spec 2200 – MSG-3*, Washington, DC, USA, 2009.

BALESTRASSI, P.P.; POPOVA, E.; PAIVA, A.P.; LIMA, J.W.M. Design of experiments on neural network's training for nonlinear time series forecasting. *Neurocomputing*, 2008

BOHORIS, G.A. Trend testing in reliability engineering. *International Journal of Quality & Reliability Management*, v.13, No. 2, p.45-54, 1996.

BRAGLIA, M.; FANTONI, G.; FROSOLINI, M. The house of reliability. *International Journal of Quality & Reliability Management*, v.24, No. 4, p.420-440, 2007.

KNEZEVIC, J.; PAPIC, L.; VASIC, B. Sources of fuzziness in vehicle maintenance management. *Journal of Quality in Maintenance Engineering*, v.3, No. 4, p.281-288, 1997.

MADU, C.N. Competing through maintenance strategies. *International Journal of Quality & Reliability Management*, v.17, No. 9, p.937-948, 2000.

MAYER, R. *Text Mining with Adaptive Neural Networks*. 2004. Dissertação de Mestrado. Universität Wien, Fakultät für Technische Naturwissenschaften und Informatik, Wien, Áustria, 2004.

SHEIKH, A.K.; AL-GARNI, A.Z.; BADAR, M.A. Reliability analysis of aeroplane tyres. *International Journal of Quality & Reliability Management*, v.13, No. 8, p.28-38, 1996.

SOHN, S.Y.; YOON, K.B.; CHANG, I.S. Random effects model for the reliability management of modules of a fighter aircraft. *Reliability Engineering & System Safety*, v.91, p.433-437, 2006.

TRIANAPHYLLOU, E.; KOVALERCHUK, B.; MANN JR., L.; KNAPP, G.M. Determining the most important criteria in maintenance decision making, v.3, No. 1, p.16-28, 1997.

XIE, M.; KONG, H.; GOH, T.N. Exponential approximation for maintained Weibull distributed component. *Journal of Quality in Maintenance Engineering*, v.6, No. 4, p.260-268, 2000.