

3

Metodologia de Previsão de Padrões de Falha

Antes da ocorrência de uma falha em um equipamento, ele entra em um regime de operação diferente do regime nominal, como descrito em [8-11]. Para detectar este estado, é necessário que seus componentes sejam monitorados, e que o estado de falha seja observável. Para esse tipo de falha pretende-se encontrar o padrão de comportamento dos componentes antes de sua ocorrência, de modo que seja possível decidir sobre a manutenção do equipamento tendo ciência do estado real da máquina.

Considera-se estado anormal de operação da máquina o período em que ela trabalhou com os parâmetros fora das especificações. Alguns desses parâmetros de operação são armazenados no VIMS. Deseja-se identificar quais indicadores de condição detectam o comportamento anormal antes de uma determinada falha ocorrer, de modo a utilizá-los no treinamento de uma rede neural que tem como objetivo reconhecer o comportamento característico.

A metodologia é formada por duas fases. A primeira fase é de aprendizado, onde são categorizados os dados das Ordens de Serviço e agrupados com os dados dos equipamentos para realizar o treinamento das redes neurais. Após o treinamento das redes inicia-se a segunda fase, que consiste na utilização das redes para detectar os estados de pré-falha e avaliar o critério de decisão que determinará a parada ou não da máquina.

A primeira etapa consiste nos quatro passos ilustrados na figura 3.1, que serão descritos nas próximas seções.



Figura 3.1 – Processo de extração de informação do histórico.

Nesta dissertação só foram considerados dois dos grandes componentes dos equipamentos, o motor e a transmissão, pois são estes os componentes mais monitorados por sensores eletrônicos. Foram utilizados os dados de Eventos e Tendência do sistema VIMS, por serem os sensores em maior número.

Foram selecionadas as dez falhas corretivas mais recorrentes, com o objetivo de reduzir o número de paradas, aumentando a confiabilidade dos equipamentos e por consequência sua disponibilidade. Entende-se por falha corretiva o evento que retirou o equipamento da produção para ser realizada uma manutenção não planejada.

Conforme ilustrado na figura 3.4, para cada Falha categorizada será criada uma rede neural isolada para o reconhecimento de um padrão pré-Falha. Essa metodologia foi adotada porque as falhas aqui estudadas podem ocorrer simultaneamente, e a utilização de uma rede genérica, além de ter uma maior complexidade para o treinamento e interpretação, poderia esconder alguma falha menos iminente.

3.1

Descrição e Tratamento da Base de Dados

Para a realização desta dissertação foi necessário trabalhar com duas bases de dados, uma referente aos dados dos equipamentos (VIMS) e a outra referente ao registro de execução de Ordens de Serviço. Para unificar as bases será utilizada a data da falha.

3.1.1

Dados dos Equipamentos

Os dados dos equipamentos são armazenados em uma base de dados Microsoft Access. Foram utilizados dois anos de dados históricos de 10 equipamentos no período de 2007 a 2008. Os dados de eventos são armazenados quando algum parâmetro monitorado excede o valor pré-determinado pelo fabricante. Os dados dos indicadores de tendência são armazenados a cada minuto no equipamento.

3.1.2

Dados das Ordens de Serviço

Os dados das Ordens de Serviços (O.S.) foram importados como relatórios em formato de arquivo texto. Foram utilizados os mesmos 2 anos de dados, de 2007 a 2008. Os registros das O.S. continham as informações de tempo de execução, tipo de manutenção, sintoma apresentado e ação executada.

Os registros das informações das O.S. são preenchidos em campos livres, o que dificulta a categorização dos campos. Para realizar a categorização de cada O.S. em um padrão de falha que será utilizada como alvo no treinamento da rede neural, as O.S. foram classificadas manualmente e agrupadas por sintoma e ação executada.

Os registros muitas vezes possuíam graves erros de digitação, o que impossibilitou uma análise automatizada dos dados com uma abordagem simples. Registros que representavam o mesmo tipo de causa eram gravados com dizeres diferentes, o que necessitou a ajuda de um especialista para a definição de quais sintomas descritos representariam o problema em questão. A amostra seria muito maior e mais robusta caso os registros fossem armazenados já com os dados de falha categorizados.

Para registros nos quais os tempos de execução dos serviços eram muito discrepantes do restante da amostra, o registro da amostra foi conservado, porém os dados de tempo de execução foram descartados e substituídos pela média da amostra, sem os pontos discrepantes.

3.2

Tratamento da Base de Dados

Para construir os padrões de treinamentos que serão utilizados no treinamento supervisionado das redes neurais, foi necessário unir as duas bases de dados, sendo que a base de dados relativa aos caminhões (VIMS) foi utilizada para calcular as variáveis de entrada e os dados das Ordens de Serviço foram utilizados como alvo do treinamento.

Conforme ilustrado na figura 3.2 os registros das ordens de serviço são categorizados e depois unificados em uma base junto com a base dos equipamentos. A base unificada é segmentada em bases menores que contêm registros de uma classe, o qual a rede tentará identificar, e uma mesma quantidade de registros que não pertencem a esta classe.

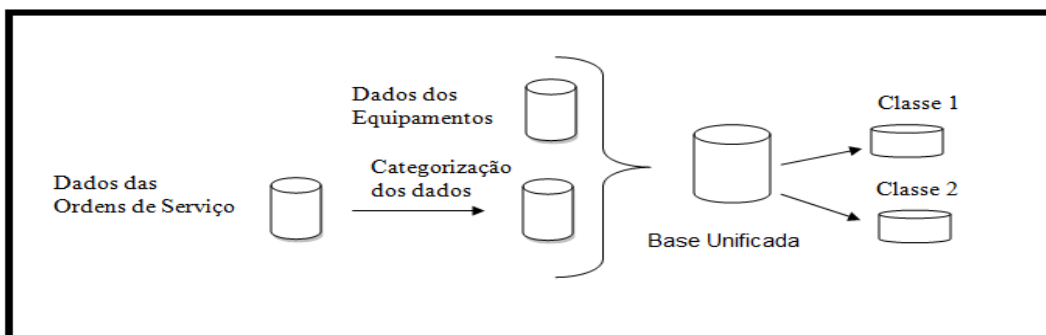


Figura 3.2 – Tratamento das bases de dados

Para formar um padrão de treinamento com os dados de entrada e a classificação desejada desses dados, a união dos bancos de dados foi realizada agrupando os dados dos sensores em um período Jt antes da ocorrência da falha. Dado um registro de falha categorizado, os dados dos sensores são agrupados no tempo em uma janela com duração Jt em dias e uma antecedência Δ em dias do momento da falha, como ilustrado na Fig. 3.3. A definição dos parâmetros Jt e Δ será discutida na próxima seção.




Figura 3.3 – Parâmetros Jt e Δ

A antecedência de Δ dias é importante para que a falha seja prevista com tempo hábil para que sua manutenção possa ser programada e executada.

3.2.1

Agregação dos Indicadores de Evento

Para os indicadores de evento, que armazenam os valores dos sensores quando estes passam do limite estipulado pelo fabricante, foram atribuídos dois valores: valor 0 para indicador desativado; valor 1 para quando o indicador está ativado.

Para agregar os indicadores de evento, foi realizado o somatório dos valores do indicador durante o período analisado. Para cada indicador i , calcularam-se os somatórios nas variáveis de evento agregadas, E_i , no período Jt :

$$e_i = 0, \text{ se evento inativo;}$$

$$e_i = 1, \text{ se evento ativo;}$$

$$E_i = \sum_{Jt} e_i; \quad (3.2)$$

Ou seja, a variável E_i é um acumulador que indica quantas vezes um dado evento i ocorreu dentro do período em análise Jt .

3.2.2

Agregação dos Indicadores de Tendência

Os indicadores de tendência são registrados a cada minuto. A principal característica desses indicadores é o fato de monitorarem pontos da máquina em que a tendência de aumento ou diminuição está diretamente ligada ao desgaste de um componente do equipamento.

Os valores dos indicadores de Tendência agrupados, T_i , são formados pela média dos valores t_i registrados a cada minuto. A informação relevante é a mudança de patamar e, portanto, esses indicadores são calculados como a média no período.

$$T_i = \frac{1}{Jt} \sum_{Jf} t_i \quad (3.3)$$

3.3

Seleção de Variáveis pelo Teste T-Student

O teste-t, conforme analisado em *Huiqing* 2002 [61], é um método eficaz e simples de ser implementado para seleção de atributos em problemas de classificação.

No teste-t aplicado para duas amostras, a hipótese nula é de que as duas médias de duas populações normalmente distribuídas são iguais. Todos esses testes são geralmente chamados de teste-t de Student embora, estritamente falando, esse nome só deva ser utilizado se assumir-se que as variâncias das duas populações também são iguais. A forma do teste utilizado, quando essa premissa não for verdadeira, é às vezes chamado de teste-t de Welch *Sawilowsky* [62]. Estes testes são muitas vezes referidos como t-testes "ímpar" ou "amostras independentes", uma vez que são normalmente aplicados quando as unidades estatísticas subjacentes às duas amostras em comparação não sejam sobrepostas.

Para selecionar as variáveis que são mais relevantes ao modelo, ou seja, as variáveis que têm mais relevância na classificação do padrão em análise, foram criados dois grupos: um grupo que agrega os valores dos indicadores, conforme relatado no item 3.2, dentro do intervalo de Δ dias antes da ocorrência do problema em análise e com duração Jt , que será nominado como grupo f ; e outro grupo com o valor dos sensores em períodos que não antecedem o problema estudado, com a mesma duração Jt , que será nominado grupo d .

É importante ressaltar que o grupo d possui amostragem mais extensa, pois o número de amostras diferentes da classe é sempre maior que o número de amostras da classe em análise, para o caso estudado. Para seleção de variáveis foi utilizado o teste-t para amostras de tamanho diferente e variância diferente, sob a hipótese nula, h_0 , da igualdade das médias:

- μ_f , média da amostra que pertence à classe em questão

- μ_f , média da amostra que não pertence à classe em questão.

$$h_o: \mu_d = \mu_f \quad (3.4)$$

A estatística de teste é definida por:

$$t = \frac{\bar{X}_d - \bar{X}_f}{S_{X_d X_f} \sqrt{\frac{1}{n_d} + \frac{1}{n_f}}} \quad (3.5)$$

Onde:

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n x_i \quad (3.6)$$

e:

$$S_{X_d X_f} = \sqrt{\frac{(n_d - 1)S_{X_d}^2 + (n_f - 1)S_{X_f}^2}{n_d + n_f - 2}} \quad (3.7)$$

$$s = \sqrt{\frac{1}{n - 1} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (3.8)$$

Sendo n_k o número de amostras do grupo k , x_i é o i -ésimo elemento da amostra.

As variáveis são ordenadas em ordem decrescente de acordo com o valor p da estatística de teste. Variáveis para as quais não se pode rejeitar a hipótese nula com o nível de significância de 5% são descartadas do modelo, enquanto as que

possuem o valor p menor que 5% estão elegíveis para serem utilizadas nos modelos.

3.4

Determinação da Topologia da Rede

Para não superestimar as redes de classificação, foi utilizada a heurística descrita em [16]:

$$N = O\left(\frac{w}{e}\right) \quad (3.9)$$

Onde e é limite do erro assumido, w é o número de parâmetros da rede e N é o número de padrões utilizados para o treinamento, ou seja, o número de padrões para treinamento deve ser da ordem de grandeza do número de parâmetros da rede divididos pelo erro desejado. Por exemplo, para um erro de 10%, o número de padrões no grupo de treinamento deve ser 10 vezes maior que o número de parâmetros da rede neural.

Para todas as redes foi utilizada apenas uma camada escondida, variando de 2 a 4 neurônios, de forma que a heurística descrita em 3.9 não seja violada.

$$w = (n_e \cdot n_o + n_o \cdot n_s) + (n_o + n_e + n_s) \quad (3.10)$$

onde n_e é o número de entradas utilizadas pela rede, n_o é o número de neurônios na camada escondida e n_s é o número de neurônios na camada de saída. O primeiro termo da equação 3.10 representa o número de pesos sinápticos entre os neurônios de cada camada, e o segundo termo representa o número de parâmetros de Bias total de cada camada. As redes de classificação utilizadas nesse trabalho só possuem um neurônio na camada de saída, pois estão classificando se as entradas representam um estágio pré-falha do equipamento ou não. Pode-se igualar $n_s = 1$, substituindo em 3.10 e obtendo com isso:

$$w = n_o(n_e + 1) + (n_o + n_e + 1) \quad (3.11)$$

3.4.2

Treinamento da Rede

Para treinar as redes foi utilizada a metodologia de Validação Cruzada, descrita em [16]. A amostra de dados que será utilizada em cada rede de classificação foi separada em três grupos: o grupo de treinamento, o grupo de validação e o grupo de teste. O grupo de treinamento é utilizado para treinar a rede utilizando o algoritmo *Backpropagation*, com o qual deseja-se minimizar o erro de saída da rede. O grupo de validação é utilizado para evitar a especialização da rede no grupo de treinamento (esses dois grupos são utilizados em conjunto na metodologia de validação *cross-validation*), enquanto o terceiro grupo serve para avaliar o desempenho da rede com dados aos quais ela nunca foi apresentada.

A essência do aprendizado back-propagation é codificar uma relação funcional (mapeamento) entre entradas e saídas, representada por um conjunto de exemplos rotulados $\{x, d\}$, e pelos pesos sinápticos e limiares de um *perceptron* de múltiplas camadas (MLP – *Multi-Layer Perceptron*). O objetivo é que a rede torne-se bem treinada, de modo que aprenda bastante sobre o passado para poder generalizar sobre o futuro. Desta perspectiva o processo de aprendizado equivale a uma parametrização da rede para este conjunto de exemplos. Mais especificamente, pode-se ver o problema de seleção da rede como sendo de escolha, dentro de um conjunto de estruturas de modelos candidatas, da “melhor” de acordo com um certo critério.

Nesta dissertação, conforme já mencionado, foi utilizada a metodologia de validação cruzada, que consiste em segmentar as amostras que serão utilizadas na fase de treinamento, em “n” grupos, separar de 10% a 20% dos grupos para serem utilizados como grupo de validação e o restante para ser utilizado como grupo de treinamento da rede. Deseja-se testar o desempenho médio da rede realizando todas, ou parte das combinações possíveis dos grupos de treinamento e validação. Para esta dissertação, a amostra reservada para treinamento foi segmentada em 10 grupos, sendo 1 grupo utilizado para validação e os outros 9 grupos para treinamento, tendo sido testadas todas as dez combinações de grupos de treinamento e validação.

Após finalizado o treinamento, a rede foi submetida ao terceiro grupo de dados (grupo de teste), avaliando-se seu desempenho. Os resultados apresentados no capítulo 4 são referentes à média do desempenho dos 10 treinamentos. O treinamento é parado quando o erro de validação sobe constantemente por 10 épocas.

A motivação aqui é validar o modelo sobre um conjunto de dados diferente daquele usado para a estimação dos parâmetros. Desta maneira, pode-se usar o sub-conjunto de validação na avaliação do desempenho de vários modelos candidatos, e então selecionar o de melhor desempenho.

Após inúmeros testes variando o limiar de decisão entre 0.3 e 0.7, o melhor resultado é atingido quando a classificação é considerada correta se a saída da rede for maior que 0.6 para a classificação de classes de pré-falha, e menor que 0.6 para classificação de classes de não falha.

Será criada uma rede para cada falha que se deseja identificar e as saídas das redes serão utilizadas para avaliação do critério de decisão conforme ilustrado na figura 3.4.

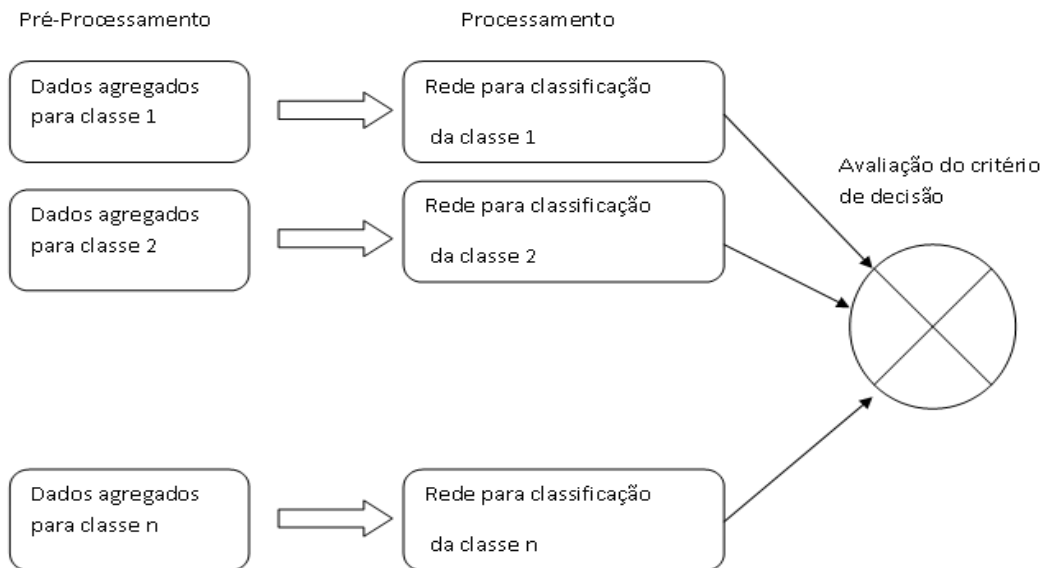


Figura 3.4 – Processamento paralelo para avaliação do critério de decisão

3.4.5

Determinação dos Parâmetros Jt E Δ

O parâmetro Δ expressa com que antecedência conseguir-se-á detectar o padrão pré-falha. Quanto maior for esse parâmetro, melhor para o operador do sistema, pois existirá mais tempo hábil para se realizar uma medida que evite a falha e uma parada não programada, O parâmetro Jt expressa quanto tempo de informação é necessário para reconhecer o padrão. Esses dois parâmetros são extremamente importantes na seleção de variáveis, pois determinam como os indicadores são agregados e quantos dias de dados serão utilizados.

O parâmetro Δ foi variado de 3 a 8 dias e a janela de tempo Jt de 8 a 20 dias. Foram selecionados os parâmetros, por meio de uma busca exaustiva, que obtiveram o melhor resultado no erro de teste da rede e foi dada prioridade ao parâmetro com maior valor, caso os erros de teste de duas redes fossem iguais.

3.5

Critério de Decisão

Deseja-se decidir se o equipamento deve ser parado ou não, baseado no valor esperado do tempo de máquina parada para executar a manutenção desejada. O tempo de máquina parada foi utilizado como critério de decisão. Outros critérios, como custo de reparo e custo da substituição da peça trocada, poderiam ser incluídos nesses cálculos, porém esses dados não estavam disponíveis.

Considera-se a saída da rede, y_i , como a probabilidade de uma Falha x ocorrer, quando y_i ultrapassa o limiar de classificação. Sendo C_a o custo da manutenção corretiva, e C_r o custo de máquina parada em revisão, o critério de decisão de parada da máquina é dado por:

$$\sum_{i=1}^n y_i \cdot C_{a_i} > C_r \quad (3.12)$$

O intervalo mínimo de tempo para uma parada programada de um equipamento é sua revisão periódica, de forma que, se o valor esperado da parada da máquina estiver acima do tempo para revisão, o equipamento deve ser parado, e executados os serviços referentes aos problemas identificados e paralelamente a revisão do equipamento. A programação das revisões se baseará não somente no tempo, mas também na condição do equipamento, reduzindo o tempo de máquina parada e reduzindo os riscos de quebra do equipamento.