

6

Conclusão e Trabalhos Futuros

6.1

Conclusões

Nesse trabalho foi desenvolvida uma metodologia de detecção de padrões pré-falha por meio de redes neurais, para apoiar a decisão da parada de um caminhão fora de estrada, com o objetivo de reduzir as paradas para manutenção corretiva. Foram analisadas 13 falhas diferentes, sendo 9 referentes ao motor e 3 referentes à transmissão.

A metodologia se mostrou, em 11 das 13 falhas, bastante eficaz para prever o padrão de falhas com base nos dados dos equipamentos. A taxa de acerto, das 11 redes utilizadas, ficou entre 85% e 95%, resultados bastante satisfatórios para esse tipo de problema de classificação. Isso indica que o método de seleção de variáveis se mostrou eficiente para reduzir o número de variáveis de entrada e a complexidade da rede.

A escolha dos maiores intervalos entre a observação do estado anormal e a ocorrência da falha permite, na prática, que o equipamento tenha sua parada programada, o que reduz o custo da mesma e aumenta o aproveitamento de janelas de oportunidade para execução da manutenção de forma preditiva.

As simulações de parada dos equipamentos com base no modelo de decisão proposto indicaram um benefício imediato de redução de downtime corretivo da máquina de até 20%, o que aumenta consideravelmente a confiabilidade do equipamento, além de reduzir o desgaste dos componentes que estão trabalhando fora do regime nominal.

Para as falhas que não conseguiram ser identificadas pelas redes, é necessária uma avaliação mais detalhada para verificar se elas são realmente observáveis pelos sensores que foram utilizados.

6.2

Trabalhos Futuros

Alguns pontos da metodologia ainda podem ser melhorados, para se obter uma melhor identificação do padrão pré-falha, e conseqüentemente uma maior redução do downtime corretivo dos caminhões fora de estrada utilizados na mineração.

O primeiro ponto é um melhor armazenamento dos dados de falha dos equipamentos, para que seja mais fácil a categorização de falhas. Os registros utilizados nesse trabalho foram obtidos de campos livres, ou seja, não categorizados, o que dificultou em muito a padronização das falhas.

O estudo da correlação entre os indicadores pode reduzir a complexidade da seleção de variáveis, assim como o número de variáveis selecionadas para o modelo, o que permitiria o aumento da complexidade das redes neurais, que foram limitadas pelo número de amostras existentes e de variáveis de entrada.

Com os dados padronizados, a inserção de novas categorias de falhas e o número de amostras de cada uma das categorias será maior e mais confiável, o que permitirá um melhor treinamento das redes.

A inclusão de novos tipos de indicadores no modelo pode também melhorar o desempenho, pois alguns tipos de falha podem não ser observáveis pelos indicadores utilizados atualmente. Pode-se também melhorar o desempenho atual das redes, ajudando a classificar melhor os padrões de falha.

Outra forma possível de melhorar a metodologia é a introdução de outros custos no modelo de decisão como: custo com peças, tempo para a próxima revisão, entre outros, para que o modelo de decisão seja mais abrangente.