

Sistemas de correias: manutenção preditiva com MCSA e redes LSTM

2.ª Parte

J.Costa ⁽¹⁾, José Torres Farinha ^(1,3), Mateus Mendes ^(1,3), J.O.Estima ⁽²⁾
joaopaulocosta1014@gmail.com, tfarinha@isec.pt, mmendes@isec.pt, jorge.estima@enging.pt
⁽¹⁾ Instituto Superior de Engenharia de Coimbra, Coimbra, Portugal
⁽²⁾ Enging – Make Solutions, Coimbra, Portugal
⁽³⁾ RCM² – Centro de Investigação em Gestão de Ativos e Sistemas de Engenharia, Coimbra, Portugal

4. MODELOS PREDITIVOS

Uma vez que os registos de falha da correia podem ser considerados como uma série temporal multivariada e que o estado atual de uma falha específica é esperado que esteja relacionado com os estados anteriores, dois modelos foram considerados para este estudo. Primeiramente, o modelo ARIMA foi considerado. Este é um modelo estatístico amplamente utilizado para análise de séries temporais [8] [9]. Os modelos ARIMA são uma classe geral de modelos usados para prever uma série temporal que, mesmo não sendo estacionária, pode ser tornada estacionária por diferenciação [22]. Estes são baseados em três componentes, especificados pelos parâmetros p , que é o número de termos autorregressivos (*lags*) a serem usados, q é a ordem da média móvel, e d a ordem da diferenciação. Ao analisar uma série temporal, se os dados indicarem não estacionariedade, a diferenciação é realizada para transformar a série não estacionária numa estacionária [23].

Posteriormente, um modelo de aprendizagem profunda foi considerado, particularmente uma LSTM [10][24], [25]. A LSTM é um tipo de RNN (Rede Neuronal Recorrente), que é uma arquitetura de rede neuronal especialmente projetada para lidar com dados sequenciais. Este é capaz de capturar e reter informação de longo prazo, ligando informação do passado recente para o presente e, até mesmo, extrapolando para o futuro. À medida que a distância entre informação relevante e a informação do passado aumenta, as RNNs convencionais tendem a perder a capacidade de aprender. Para resolver este problema foram projetados múltiplos “portões” de controlo na arquitetura LSTM. Esses portões ajudam a regular o fluxo de informação ao longo do tempo, permitindo que a rede aprenda com sequências de dados mais longas. A rede LSTM, portanto, é amplamente reconhecida como uma das abordagens mais bem-sucedidas para lidar com dados sequenciais em redes neuronais. A Figura 4 ilustra a estrutura interna de uma LSTM.

“ A LSTM é um tipo de RNN (Rede Neuronal Recorrente), que é uma arquitetura de rede neuronal especialmente projetada para lidar com dados sequenciais.




Figura 4. Estrutura interna de uma LSTM.

Os valores dos hiperparâmetros foram otimizados experimentalmente. As Tabelas 2 e 3 apresentam os parâmetros usados para cada modelo.

Tabela 2. Características do modelo ARIMA.

Modelo	p	d	q
ARIMA	3	1	2

Tabela 3. Características dos modelos LSTM.

Modelo	LSTM - Sigmoid	LSTM - Tanh	LSTM - ReLU
Número de camadas ocultas	1	1	1
Número de unidades de memória	35	40	35
Optimizer	ADAM	SGD	ADAMAX
Tamanho do lote	2	2	2
Épocas de treino	100	100	100

Para ambos os modelos LSTM e ARIMA foi utilizada uma série temporal de dados representando o desempenho histórico da amplitude da falha das correias. Cada ponto de dados na série temporal representa uma medição específica da frequência de falha da correia ao longo do tempo.