

Comparando Redes Neurais na Inferência de Planos de Produção

Gabriel A. P. dos S. Carneiro¹, P. Matos², P. Matos³

¹Estudante de mobilidade, IPB, Portugal

gabri14el@gmail.com

²Professor do Instituto Politécnico de Bragança, Portugal

pmatos@ipb.pt

³CEO, Techwelf, Portugal

marina@techwelf.com

Contextualização

No âmbito do projeto eLeveling System, em desenvolvimento na empresa Techwelf para um dos maiores produtores mundiais de componentes para a indústria automóvel, o trabalho realizado pelos autores visou dar continuidade à construção de um sistema de apoio à decisão (SAD) para definição de planos de produção, tendo por base um histórico de quase três anos de planos de produção e de registos de encomendas.

A mais-valia do SAD é aproximar a produção à procura efetiva, minimizando a existência de stocks e indo de encontro à base de funcionamento do eLeveling System que assenta num modelo pull-based.

Objetivos

Investigar a utilização de redes neurais, Multilayer Perceptron (MLP) e Long short-term memory (LSTM) para estimar a procura de produtos e assim auxiliar o planeamento de produção.

- Tratar dados para exclusão de séries temporais não previsíveis;
- Testar o acondicionamento dos dados para inserção nos modelos de previsão;
- Definir estratégias e parâmetros para treinamento dos modelos neurais;
- Definir parâmetros para os modelos;
- Avaliar o desempenho de cada modelo neuronal.

Metodologia

- Tratamento dos dados: limpeza, disposição em janelas (Fig. 1) e suavização (filtro de Savitzky–Golay);
- Definição dos modelos neurais: um modelo por produto, definição dos parâmetros de cada modelo e escolha do framework de implementação (Keras);
- Avaliação dos modelos utilizando a quantidade produzida num mês como referência.

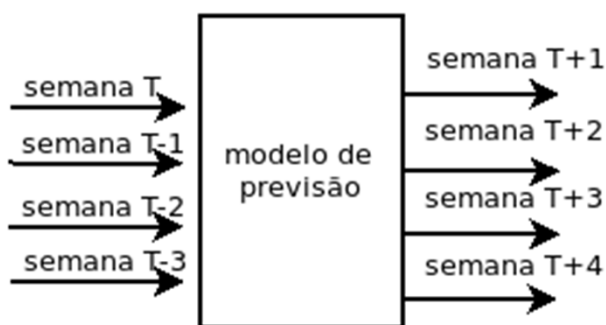


Figura 1. Modelo de previsão com entrada em janela

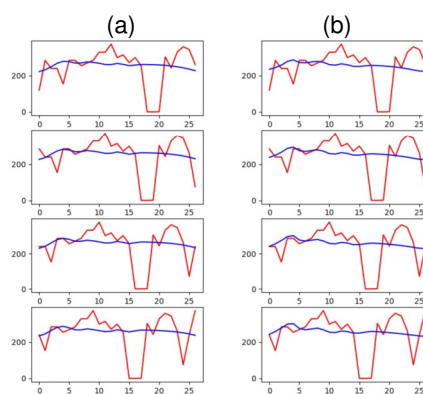


Figura 2. Resultados para LSTM(a) e MLP(b)

Conclusões

O modelo MLP teve um erro de previsão mensal de 54%, enquanto o LSTM teve erro de 51.9%. O fraco desempenho dos modelos pode ter sido causado por fatores como disposição dos dados (vide Fig. 2) e tamanho reduzido das amostras de dados.

Para trabalho futuro, pensa-se em considerar características de séries temporais, treinar um modelo com dados de itens já fora de produção e aplicar *fine tuning* para treinar cada um dos produtos individuais.