

# APRENDIZAGEM DE MÁQUINA APLICADA À ESTIMAÇÃO DO CONSUMO DE ENERGIA ELÉTRICA EM SISTEMAS DE MANUFATURA

Lucas Kazuaki de Barros Yamane Nonogaki<sup>1</sup>, Prof. Dr. Fábio Lima<sup>2</sup>

<sup>1</sup> Departamento de Engenharia Elétrica, Centro Universitário FEI

<sup>2</sup> Departamento de Engenharia de Produção, Centro Universitário FEI

lucasonogaki1@gmail.com e flima@fei.edu.br

**Resumo:** Este trabalho consiste em um estudo de gerenciamento de energia em sistemas de manufatura usando o *software Tecnomatix Plant Simulation*<sup>®</sup> implementando técnicas inovadoras com o uso de redes neurais artificiais. Após uma série de treinamentos com o uso da ferramenta de redes neurais as plantas industriais foram simuladas e os resultados forneceram estimativas de consumo energético muito precisas.

## 1. Introdução

Devido aos crescentes custos de geração, transmissão e distribuição de energia elétrica no Brasil, agregados às mudanças climáticas, uma grande pressão foi criada sobre as indústrias para que os meios de produção sejam remodelados para serem mais sustentáveis. Neste cenário surge uma grande variedade de estudos apontando o potencial de se melhorar os indicadores de eficiência energética. Com o uso da manufatura digital, os processos da indústria estão cada vez mais digitalizados e já existem programas computacionais como o que é apresentado neste trabalho capazes de realizar diversas simulações, gerenciamento e monitoramento de energia. A digitalização de processos gera cada vez mais dados que podem ser usados para resolver diversos problemas dentro das indústrias com o intuito de reduzir o consumo de energia elétrica. Portanto, para analisar a massiva quantidade de dados, conceitos de aprendizado de máquina como o de redes neurais artificiais serão de singular importância.

## 2. Revisão da literatura

Para iniciar o trabalho uma extensa revisão da literatura foi realizada buscando adquirir conhecimento dos diversos métodos e técnicas de gerenciamento de energia elétrica. Além disso, esta etapa inicial de revisão foi de suma importância uma vez que os trabalhos realizados por outros autores serviram como um alicerce para o desenvolvimento das simulações das manufaturas.

A eficiência energética de uma fábrica depende das relações baseadas no tempo entre os diversos equipamentos, planos de produção, execução, o edifício em que a fábrica está contida e o clima do ambiente. Assim, quanto mais melhorias são realizadas mais difícil é para se identificar novas áreas para um mais profundo melhoramento [3].

No passado os trabalhos de pesquisa eram focados especialmente em reduzir impactos ambientais em pequenas escalas com uma ou várias máquinas, porém, produzindo apenas um único produto. Mesmo com um número de empresas tomando providências, trabalhando para reduzir picos de energia e reduzindo o consumo geral de energia, companhias fornecedoras de energia estão empenhando-se para tentar acompanhar a crescente demanda por energia. [2]

## 3. Metodologia

Os sistemas iniciais escolhidos são provenientes dos trabalhos de Pereira e Lima [2] e Chang et al. [1]. Foram escolhidos por serem sistemas de manufatura com classificações e especificidades distintas. O primeiro é caracterizado como um “*jobshop*” e o segundo como um “*flowshop*”.

Uma variável chamada “Velocidade” foi criada baseando-se no trabalho criado por Song B. et al [1] e o trabalho de Sharma, Zhao e Sutherland [4]. O tempo de processo TP é calculado usando a variável “Velocidade” e o tempo de processo TP’ de cada peça e assim temos:

$$TP = TP' * 100 / \text{Velocidade} \quad (1)$$

Para o cálculo da energia E, a seguinte equação foi inserida para definir os estados em que a máquina está ociosa ou trabalhando, sendo E’ o consumo de energia padrão das máquinas:

$$E = E' * \text{Velocidade} / 100 \quad (2)$$

Observa-se que para os cálculos de energia a variável “Velocidade” multiplica a energia E’ criando uma relação proporcional entre a velocidade que a máquina trabalha e seu consumo energético. Entretanto, para o cálculo do tempo de processo, esta variável divide o tempo TP’ criando uma relação de proporcionalidade inversa em que um aumento de velocidade reduz o tempo de processo TP. Para as simulações a velocidade do sistema podia variar de forma aleatória entre 90% e 110% da velocidade original.

O software *Plant Simulation*<sup>®</sup> usa o método de propagação reversa (*backpropagation*) para o treinamento da rede neural. Este método de gradiente descendente minimiza os erros entre as saídas da rede e os dados de treinamento fornecidos. Nas configurações da ferramenta é possível selecionar se a rede terá três ou quatro camadas e inclusive o número de neurônios em cada camada. Entretanto, os valores padrões foram mantidos ou pouco alterados apenas nas situações em que a complexidade da simulação exigia um número maior de neurônios para lidar com os dados.

Uma planta industrial foi construída usando o sistema de manufatura de *jobshop* e está representada pela Figura 1. Baseando-se no sistema de manufatura do tipo *flowshop* uma segunda planta foi criada mantendo-se a lógica do controle de velocidade para as máquinas e o uso de redes neurais para as melhorias e está representada pela Figura 2.



Figura 1 – Planta industrial simulada usando o sistema de manufatura de *jobshop*.



Figura 2 – Planta industrial simulada usando o sistema de manufatura de *flowshop*.

#### 4. Resultados

Uma das ferramentas que auxiliam a aplicação das redes neurais é o *Experiment Manager* que é responsável pela criação de diversos experimentos na planta simulada. Estes experimentos produzem uma série de dados usados para o treinamento das redes neurais. Quanto maior foi o número de experimentos criados menores foram os erros no final dos treinamentos. Ao longo do trabalho este número variou desde apenas 25 experimentos até 7000 experimentos. Nota-se que este parâmetro afeta tanto o desempenho do sistema como o tempo que o computador leva para realizar as simulações.

Após o fim do treinamento o erro final foi de 0.415% para a aplicação no sistema *jobshop* e um valor de erro médio final para as saídas de 0,119% no caso do sistema *flowshop*. Utilizando então a função de previsão da ferramenta *Neural Net* para diminuir o consumo energético a configuração recomendada foi gerada e conseguiu estimar com muita precisão o gasto energético da planta.

De acordo com a previsão criada para o primeiro caso o consumo energético deve ser de 1770 kWh com um tempo de *makespan* de 9 horas, 13 minutos e 20 segundos. Ao testar a configuração recomendada na planta o consumo obtido foi de 1753 kWh com um tempo de 9 horas, 10 minutos e 42 segundos. Comparando este resultado com a situação onde todas as máquinas têm velocidade padrão de 100% a energia consumida foi de 1798 kWh revelando que a rede neural foi capaz de reduzir o consumo de energia e estimar os parâmetros da manufatura projetada.

A previsão criada para o segundo caso revelou que para a configuração de velocidades recomendadas o consumo de energia total seria de 9.75kWh com um tempo total de 4 minutos e 42 segundos. Testando os valores sugeridos para redução do consumo energético obteve-se um consumo total de 9.71kWh com o tempo total de 4 minutos e 42 segundos. Isso ressalta que o treinamento da rede neural foi bem-sucedido. Além disso, o experimento mostra que algumas das máquinas trabalharam mais rápidas do que a velocidade padrão e mesmo assim o tempo total e a energia consumida caíram em relação a planta simulada com todas as velocidades em 100%, onde foram consumidos 10.24kWh com um tempo de 4 minutos e 50 segundos.

#### 5. Conclusões

Cada uma das plantas simuladas com o software *Plant Simulation*® foi criada com graus crescentes de complexidade aplicando a ferramenta de redes neurais. Esta oferece diversos parâmetros para controlar o aprendizado da rede e mostrou que é uma ferramenta muito poderosa. Após realizar os treinamentos, a rede conseguiu encontrar as relações entre as variáveis de entrada e saída revelando estimativas de gasto energético muito satisfatórias.

#### 6. Referências

- [1] Chang, Q., G. Xiao, S. Biller and L. Li. "Energy saving opportunity analysis of automotive serial production systems (March 2012)," *Automation Science and Engineering, IEEE Transactions on*, vol. 10, n. 2, pp. 334-342, 2013.
- [2] M. S. Pereira and F. Lima, "A Machine Learning Approach Applied to Energy Prediction in Job Shop Environments," *IECON 2018 - 44th Annual Conference of the IEEE Industrial Electronics Society, Washington, DC, 2018*, pp. 2665-2670
- [3] SONG, B. et al. *Data-driven Approach for Discovery of Energy Saving Potentials in Manufacturing Factory. 25th CIRP Conference on Life Cycle Engineering. Copenhagen: [s.n.]. 2018. p. 330-335.*
- [4] SHARMA, A.; ZHAO, F.; SUTHERLAND, J. *Ecnological scheduling of a manufacturing enterprise operating under a time-of-use electricity tariff. Journal of Cleaner Production, 1 Dezembro 2015. 256-270.*

#### Agradecimentos

Ao Centro Universitário FEI por disponibilizar os laboratórios para execução das simulações e desenvolvimento de todo o trabalho.

<sup>1</sup> Aluno de IC CNPq-Pibit (projeto PIBIT010/18). Projeto com vigência de 08/18 a 08/19.