

PREDIÇÃO DE FLUXO DE MATERIAL EM UMA RECUPERADORA DE CARVÃO UTILIZANDO REDE NEURAL

ANDRÉ C. VENTORIM*, RODRIGO V. ANDREÃO*

*Instituto Federal do Espírito Santo - IFES, Programa de Pós graduação em Engenharia Elétrica
Avenida Vitória, 1729 – Jucutuquara, 29040-780 – Vitória – ES

E-mails: andrecaliman@gmail.com, rodrigova@ifes.edu.br

Abstract— The Artificial Neural Networks (ANN) are widely used in various fields of knowledge and industry in general. This work will use the ANN to estimate the instantaneous flow of material produced by a Reclaimer Buckets wheel (RC). For this, the flow estimation is based on the intensity of the electric current of the bucket wheel of the motor to make. ANN's different topologies were implemented with emphasis on the NARX topology. The ANN was trained and tested with real data obtained from a RC with capacity of 2000 ton/h. The obtained results are superior to the currently used model for this purpose. The estimation flow can be employed in a feedback PID controller (Proportional, Integrative and Derivative) for controlling the flow of material on the conveyor belts.

Keywords— Artificial Neural Network (ANN). Flow control. Reclaimer (RC). Estimated flow.

Resumo— As Redes Neurais Artificiais (RNA) são amplamente empregadas nas mais diversas áreas do conhecimento e na indústria em geral. No presente trabalho, a RNA é utilizada para estimar o fluxo instantâneo de material produzido por uma Recuperadora de Roda de Caçambas (RC). A estimativa do fluxo foi feita a partir da informação da intensidade da corrente elétrica do motor da roda de caçamba para fazer uma estimativa da vazão real. Diferentes topologias de RNA foram implementadas com destaque para a topologia NARX. A RNA proposta foi treinada e testada com dados reais obtidos de uma RC com capacidade de 2.000 t/h. Os resultados obtidos foram superiores ao modelo atualmente empregado para tal fim. A estimação do fluxo poderá ser empregada na realimentação de um controlador PID (proporcional, integrativo e derivativo) para controlar o fluxo de material nas correias transportadoras.

Palavras-chave— Rede Neural Artificial (RNA). Controle de fluxo. Recuperadora (RC). Estimação do fluxo.

1 Introdução

A cada dia que passa a indústria desenvolve maneiras de aperfeiçoar recursos utilizados em sua cadeia produtiva para que possa potencializar a produção poupando recursos naturais, como, por exemplo, a água, energia elétrica ou matéria prima. A utilização das técnicas de controle no meio industrial não é mais uma novidade e sim uma realidade. A discussão que as máquinas poderão substituir a mão de obra humana continua, mas hoje em dia a tecnologia vem auxiliando e melhorando as operações manuais em grande escala.

Apesar disso ainda é bastante grande a demanda de soluções ótimas para o problema da baixa eficiência dos processos industriais. Um exemplo disso é a perda de produção de minério de uma empresa mineradora, em decorrência do sobrefluxo ou baixo fluxo nas correias transportadoras.

O excesso de material nas correias provoca uma série de prejuízos para a empresa tais como desgaste prematuro dos componentes da recuperadora e transportadores, paradas por entupimentos nas transferências de uma correia para outra e também queda de material, havendo perdas e retrabalho para efetuar limpeza das máquinas.

A variabilidade de fluxo também afeta o tempo de carregamento de vagões no silo de carvão devido a vazão média da operação ficar abaixo da nominal da recuperadora que é de 2.000 t/h, impactando diretamente na produtividade. Nos dados de vazão históricos para desenvolvimento do trabalho, a vazão média não passou de 1.250 t/h. Em virtude da localização da balança distar 33 metros do centro da roda

de caçamba, há um atraso de aproximadamente 11 segundos entre a ação manual do operador e a medição do fluxo, conforme a figura 1.




Figura 1. Atraso da medição da vazão

No trabalho desenvolvido por Lopes (2012), onde são empregados dados do Terminal Portuário de Ponta da Madeira, localizado em São Luis - MA, foi utilizado o método dos mínimos quadrados para estimar os parâmetros do modelo linear ARX para fazer a predição do fluxo de minério de ferro. A predição do fluxo de minério foi baseada na informação da corrente elétrica do motor da roda de caçamba. Os resultados obtidos foram considerados bons uma vez que a informação de predição foi aplicada a um controlador PID cuja malha de controle é mostrado na figura 2, reduzindo a variabilidade de material e resultando em ganhos na produção.




Figura 2. Malha de controle em funcionamento

Outros métodos de controle são utilizados para o controle de fluxo em recuperadoras tal como o Preditor de Smith, utilizado por Hong e Kang (1999), mas esse trabalho não se propõe a explorar outros métodos de controle para sistema com tempo morto, mas sim estimar a vazão minimizando o atraso gerado pela distância da balança até a roda de caçamba da recuperadora.

O método atual apresenta um erro na predição tornando necessário utilizar meios matemáticos para corrigir o referido erro. Tal método gera um atraso no fluxo estimado, podendo deixar o controle instável. O presente trabalho tenta minimizar o erro da predição para evitar métodos de correção da vazão estimada.

A predição da vazão instantânea é utilizada como realimentação de um controlador PID com objetivo de reduzir a variância de fluxo proveniente da operação manual mostrado na figura 3.




Figura 3. Gráfico de vazão

Neste contexto, o presente trabalho propõe um novo modelo de predição do fluxo de minério baseado em uma Rede Neural Artificial (RNA). A RNA faz a predição do fluxo de material instantâneo em uma recuperadora de carvão através da corrente elétrica do motor da roda de caçamba. Para efeito de análise do trabalho desenvolvido, foi feita a comparação com o modelo de predição utilizado atualmente, tendo sido usado um simulador em tempo real através do OPC Server (OLE for Process Control) do Rslinx comunicando com o Simulink®.

Na seção (2) são apresentadas algumas configurações das redes Perceptron de múltiplas camadas (PMC) utilizadas ao longo do desenvolvimento do

trabalho e método de filtragem utilizado. Os melhores resultados das redes testadas podem ser vistos na seção (3) junto com resultado da simulação real na planta. Por fim, as conclusões deste artigo estão na seção (4).

2 Materiais e Metodologia

Em malhas fechadas de controles é necessário mensurar sinais do processo e variantes no tempo para tomada de decisões do controlador. Muitas vezes esses sinais sofrem atrasos ou são atrasados no tempo referente à variável controlada, tendo necessidade de aumentar a complexidade do controlador. Uma maneira de reduzir essa complexidade é prever o sinal eliminando ou reduzindo os atrasos através de métodos de predições de sistemas variantes no tempo.

As redes Perceptron de múltiplas camadas (PMC) podem ser configuradas de tal forma a resolverem sistemas dinâmicos.

2.1 Rede PMC de entradas atrasadas no tempo

Para aplicar a PMC em sistemas variantes no tempo para previsão (predição) de valores futuros, uma das estratégias possíveis é a utilização das entradas atrasadas no tempo, conforme figura 4.




Figura 4. Topologia PMC com entradas atrasadas

Na topologia TDNN (Time Delay Neural Networks), como é chamada a PMC com entradas atrasadas no tempo, a ordem do preditor é determinada pelo n_p , ou seja, o número de entradas atrasadas. Essa coluna de entradas atrasadas, vista na figura 4, tem efeito de memória, garantindo que amostras anteriores que refletem o comportamento temporal do processo sejam sempre inseridas dentro da rede (Silva, Spatti, Flauzino, 2010).

2.2 Rede PMC de saídas recorrentes às entradas

A diferença da arquitetura com saídas recorrentes às entradas da topologia TDNN é a composição de realimentação dos sinais de saída produzidos em frações de tempos anteriores, visto na figura 5.




Figura 5. Topologia PMC de saídas recorrentes às entradas

A RNA com saídas recorrentes funcionam como um modelo auto-regressivo não linear com entradas exógenas, NARX (*Nonlinear Auto-Regressive with exogenous inputs*), modelo utilizado para desenvolvimento do trabalho.

2.3 Filtragem dos Dados

Na figura 6 pode-se observar o sinal original de vazão coletado do CLP (Controlador Lógico Programável), escalonado de 0 a 3000 t/h, em azul. Trata-se de um sinal com ruídos e em formato de degrau.




Figura 6. Fluxo de material com e sem filtro

Para reduzir o ruído foi aplicada a função medfilt1, que é uma filtragem mediana para vetor unidirecional. Foi adotada a ordem igual a 15, o que corresponde a 1,5 segundos de dados para cálculo da mediana. Após a filtragem através da mediana foi observada a redução dos ruídos tipo impulsivos, mas o formato do gráfico continuou em degrau. Para suavizar o gráfico obtendo um melhor desempenho no treinamento das RNA, após a filtragem pela mediana, foi utilizado um filtro de média móvel, obtendo a linha verde da figura 6.

3 Resultados

A principal topologia da RNA adotada foi definida com duas camadas de neurônios e entradas compostas de três sinais de corrente, a atual mais duas atrasadas e três saídas recorrentes de vazão, como mostra na figura 7.




Figura 7. Topologia de rede adotada em malha fechada

Para concretizar o melhor funcionamento da rede NARX para o problema proposto foi realizada análise gráfica da correlação da vazão versus a corrente, observada na figura 8.




Figura 8. Gráfico de correlação (Vazão x Corrente)

Observa-se que os dados ficam muito dispersos no gráfico não sendo possível extrair uma característica linear da corrente em função da vazão, confirmando a não linearidade do sistema e a necessidade de uma modelagem para problemas não lineares. Para gerar o gráfico da dispersão, figura 8, foi necessário retirar o atraso da vazão em relação a corrente.

3.1 PMC com seis neurônios e uma camada escondida

A rede que apresentou melhor resultado nos treinamentos e validações foi a PMC com uma camada escondida com seis neurônios. O acréscimo de camadas e neurônios não surtiu efeito no resultado.

Para o treinamento com malha aberta, onde as saídas recorrentes são do banco de dados utilizado para treinamento e não a saída estimada realimentando a entrada da rede, como mostra na figura 9, a raiz do erro quadrático médio (REQM) foi de 2,54 toneladas.




Figura 9. Topologia de rede adotada em malha aberta

Para a real simulação, a fim de saber o resultado da rede, foi fechada a malha da RNA, conforme figura 5, e realizada uma nova simulação com os dados de treinamento. Na figura 10 pode ser visto o desempenho do estimador ao fechar a malha, que naturalmente teve uma redução do desempenho.




Figura 10. Teste com malha fechada

A REQM passou de 2,54 toneladas, em malha aberta, para 146 toneladas com a malha fechada. O maior erro do valor estimado para além do valor real foi de 492,53 toneladas, enquanto que o maior erro aquém do valor real foi de 305,34 toneladas, podendo ser visto em mais detalhes na figura 10.

Foram aplicados na rede com malha fechada dados novos, ou seja, que não pertenceram ao conjunto de dados de treinamento, a REQM foi de 105,35 toneladas, já o maior erro do valor estimado para além do valor real foi de 189,74 toneladas, enquanto que o maior erro aquém do valor real foi de 525,58 toneladas. O resultado gráfico está mostrado na figura 11.




Figura 11. Validação com malha fechada

3.2 NARX x ARX

Para efeito de comparação, a figura 12 mostra a vazão real e vazões estimadas pelos modelos NARX e ARX (Lopes, 2012). Nessa simulação foram aplicados novos dados que até o presente momento não haviam sido aplicados em nenhuma topologia




Figura 12. NARX x ARX

O gráfico em vermelho mostra a vazão estimada pelo modelo NARX. Pode-se observar que ela ficou mais próxima da vazão real em azul do que o modelo ARX representado na cor ciano.

3.3 Operação da Rede NARX

Nesta etapa, para avaliar o sistema em uma operação real, descreveu-se a aplicação do sistema preditor RNA proposto utilizando os recursos do *Simulink*®. Para tanto, foi necessário configurar um servidor OPC para acessar os CLPs da planta.

Para simular as RNA em tempo real foi utilizado o recurso do aplicativo RSLinx Professional, mostrado na figura 13, da Rockwell, utilizado para fazer o link de acesso dos CLPs, onde é configurado o servidor OPC.




Figura 13. RSLinx

Depois de configurado *Simulink*® e RSLinx foi monitorada a operação da recuperadora para submeter o projeto da rede diante de novos dados online, utilizando o recurso do drive OPC. Um trecho da rede em operação pode ser visto na figura 14.




Figura 14. – Gráfico da operação

Pode-se observar no resultado da operação da rede a antecipação do fluxo estimado (cor preta) em relação ao fluxo real (na cor ciano).

Foram exportados os dados para o *workspace* do MATLAB para validação e melhor visualização, mostrado na figura 15.




Figura 15. Operação

A rede ficou em operação estimando a vazão por 50 minutos obtendo uma REQM de 162,48 toneladas, aonde o maior erro do valor estimado para além do valor real foi de 382,36 toneladas, enquanto que o maior erro aquém do valor real foi de 532,29 toneladas.




Figura 16. Gráfico do erro entre a vazão real e saída da rede

4 Conclusão

Neste trabalho foram efetuadas diversas simulações buscando aprimorar um novo modelo de predição baseado em RNA para estimar o fluxo de material em uma correia transportadora de carvão. A informação empregada para a predição foi a medida da intensidade da corrente elétrica do motor de uma roda de caçamba de uma recuperadora. Foram variados os números de camadas escondidas, os números de entradas atrasadas e saídas recorrentes, alteradas as configurações dos filtros dos sinais de entrada, topologia da rede, seleção de dados, entre outras. Pela análise dos resultados pode-se concluir um melhor desempenho da topologia NARX em relação à ARX uma vez que para a simulação descrita anteriormente a topologia ARX apresentou uma REQM

maior que a NARX, aproximadamente 172,33 toneladas enquanto que o modelo proposto neste trabalho atingiu 141,42 toneladas.

No trabalho de Lopes (2012), uma etapa de pós-processamento chamada de Aprendizagem por Reforço por Diferença foi implementada, buscando auxiliar o modelo ARX a trazer o erro médio estacionário para zero. No presente trabalho não foi implementado tal algoritmo, pois a ideia inicial era maximizar o desempenho do estimador sem utilizar outras técnicas para correção.

Para estimar o fluxo de carvão foi utilizada a corrente elétrica, que é a somatória vetorial da parte reativa com a ativa do motor. Como trabalhos futuros, pretende-se avaliar o emprego da potência ativa que é a parcela responsável para realizar trabalho em um motor de corrente alternada (CA). A utilização desta informação, caso esteja disponível, poderá melhorar o resultado na estimativa do fluxo.

Outro ponto importante para melhorar o desempenho da RNA seria inserir uma nova entrada, que seria o ângulo de inclinação da lança, o qual interfere na forma como acontece o contato da roda de caçamba com o material.

Agradecimentos

Agradeço a todos que contribuíram para a realização deste trabalho, principalmente ao Bruno Eduardo Lopes pela disponibilização de informações importantes para o trabalho.

Referências Bibliográficas

- Lopes, Bruno Eduardo. Otimização de Recuperadoras de Rodas de Caçambas. 16º Seminário de Automação & TI Industrial – ABM (Associação Brasileira de Metalurgia, Materiais e Mineração), 2012.
- Silva, Ivan Nunes da. Redes neurais artificiais: para engenharia e ciências aplicadas / Ivan Nunes da Silva; Danilo Hernane Spatti; Rogério Andrade Flauzino. São Paulo: Artiber, 2010.
- Ogata, Katsuhiko. Engenharia de controle moderno. 4 ed. São Paulo: Editora Pearson Prentice Hall, 2003.
- Hong, .K .S, Kang .D .H. Reclamer Control: Modeling, Identification, and a Robust Smith Predictor. International Conference on Intelligent Robots and Systems. IEEE, 1999.
- Memória descritivo do Terminal de Praia Mole. Disponível em: <http://www.vale.com/PT/business/logistics/port-s-terminals/Documents/pdf/memorial_descritivo_terminal_praia_mole.pdf>. Acesso em: 15 de janeiro de 2015.