

ESTIMATIVA DA ESPESSURA DE TIRAS DE AÇO EM LAMINADOR DE ACABAMENTO UTILIZANDO TÉCNICAS DE APRENDIZADO DE MÁQUINA

Thaynara Leal da Silva¹
Daniel Cruz Cavalieri²
Flávio Garcia Pereira³

Resumo

Este trabalho propõe o estudo do desenvolvimento de um Sensor Virtual para o monitoramento da espessura da tira de aço no laminador de acabamento. Foram utilizadas técnicas de aprendizado de máquina para realizar a seleção dos parâmetros que mais influenciam na variável de saída, como também para a modelagem do sensor virtual. Foram testados três métodos de regressão para validação do modelo do sensor virtual: i) Árvore de decisão, ii) Floresta de Decisão e iii) Máquinas de Vetores Suporte com Regressão (SVR). Os resultados obtidos apresentaram erro médio quadrático inferior a 0,6% para dois dos métodos abordados, provando que é possível se estimar a espessura da tira de aço utilizando sensores virtuais.

Palavras-chave: Sensor Virtual; Espessura de Tiras de Aço; Aprendizado de Máquina.

ESTIMATIVE OF STRIP STEEL THICKNESS IN FINISHING MILL LINE BY USING MACHINE LEARNING TECHNIQUES

Abstract

This work proposes the study of the development of a Virtual Sensor for monitoring the thickness of the steel strip in the finishing mill. Machine learning techniques were used to perform the selection of the parameters that had more influence over the output variable, as well as the modeling of the virtual sensor. Three regression methods had been tested for validation of the virtual sensor model: i) Decision tree, ii) Decision Forest, and iii) Support Vector Machines with Regression (SVR). The obtained results showed a Root Mean Square Error (RMSE) smaller than 0,6% for two of the presented methods, which proves that it is possible to estimate the thickness of the steel strip using virtual sensors.

Keywords: Virtual Sensor; Strip Steel Thickness; Machine Learning.

¹ Engenheira de Controle e Automação, Assistente Técnica de Confiabilidade, ArcelorMittal Tubarão, Programa de Pós-Graduação em Engenharia de Controle e Automação, Instituto Federal do Espírito Santo, Serra, Espírito Santo, Brasil.

² Engenheiro Eletricista, Doutor, Professor EBTT, Programa de Pós-Graduação em Engenharia de Controle e Automação, Instituto Federal do Espírito Santo, Serra, Espírito Santo, Brasil.

³ Engenheiro Eletricista, Doutor, Professor EBTT, Programa de Pós-Graduação em Engenharia de Controle e Automação, Instituto Federal do Espírito Santo, Serra, Espírito Santo, Brasil.

1 INTRODUÇÃO

A indústria siderúrgica é caracterizada por processos de alta complexidade operados por sistemas de controle modernos. Controle de Processo avançado é bastante utilizado para aumentar a eficiência, otimizar a operação do processo e produzir produtos de boa qualidade [1]. Devido a essa alta qualidade dos produtos, demandada pelos clientes e pelo mercado, é necessário um bom conhecimento do sistema e de suas variáveis de processo [2], para, durante o processo de produção, alcançar os resultados desejados. Sensores e outras fontes de informação são usados para medir a condição do sistema. No entanto, as medições de alguns analisadores são lentas, pouco frequentes e por vezes pouco confiáveis [1].

Objetivando superar estas questões relacionadas a alguns sistemas de medição, o uso de técnicas estatísticas multivariadas na indústria tem aumentado nos últimos anos. Técnicas de inteligência artificial estão sendo empregadas para a otimização da fabricação, redução de custos e maximização da qualidade do produto final. As aplicações mais comuns são no contexto de sensor virtual que é, basicamente, o modelo matemático do processo que utiliza variáveis facilmente mensuráveis para estimar uma variável de processo [3-8]. Essa capacidade de inferir uma medição em tempo real e com boa precisão torna os sensores virtuais úteis em várias áreas, inclusive na indústria siderúrgica.

O desenvolvimento de sensores virtuais pode ser baseado em análise de regressão simples [7], Análise de Componentes Principais (*Principal Component Analysis* – PCA) [9], Redes Neurais [10], Máquinas de Vetores Suporte (*Support Vector Machines* – SVM) [11], Mínimos Quadrados Parciais (*Partial Least Squares* – PLS) [12] e Filtro de Kalman [13].

Em [7], os autores propõem uma combinação de modelos de regressão linear (*Mixture of Univariate Linear Regression Models* – MULRM) aplicados em processos variantes no tempo e em problemas de sensores virtuais. O método proposto foi comparado com quatro outros algoritmos do estado da arte e os resultados obtidos pelo método MULRM apresentaram os melhores desempenhos. Uma nova abordagem para modelagem de sensores virtuais chamada Mistura Semi-supervisionada Robusta PPCR (*Robust Semi-supervised Mixture Probabilistic Principal Component Regression*) é proposta em [9] para lidar com os problemas robustos de modelagem de sensores virtuais. Os autores afirmam, com base nos resultados, que o método proposto por eles é mais estável para previsões de qualidade em tempo real.

Um método baseado na Rede Neural Hierárquica Auto-Associativa (*Auto-Associative Hierarchical Neural Network* – AHNN) é apresentado em [10] para explorar os problemas de monitoramento de processos químicos com um grande número de parâmetros de entrada. As AHNNs consistem em duas partes: grupos de sub-redes baseadas em Redes Neurais Auto-Associativas bem treinadas (AANNs) e uma rede principal. Para a etapa de classificação, é adotado o método de Classificação de Atributos de Dados de Extensão (*Extension Data Attributes Classification* – EDAC), criando, assim, um sensor virtual usando AHNN baseado em EDAC (EDAC-AHNN). Os resultados do modelo EDAC-AHNN foram comparados com os dados experimentais extraídos da literatura e o modelo proposto se mostrou bastante eficiente.

Em [11], os autores apresentam a Máquina de Vetores de Suporte (SVM, em inglês), um poderoso método de aprendizado de máquina baseado na teoria de aprendizado estatístico (*Statistical Learning Theory* – SLT), na modelagem de sensores virtuais e,

com isso, propõem um novo método de modelagem de sensores virtuais baseado em SVM. Os modelos obtidos foram aplicados para estimar do ponto de congelamento do óleo diesel leve em uma coluna de destilação. As saídas estimadas dos sensores virtuais SVM corresponderam aos valores reais do ponto de congelamento do óleo diesel leve. Os resultados obtidos mostraram que as SVMs fornecem um método eficaz para a modelagem de sensores virtuais e pode ser utilizado em aplicações de processos industriais.

Nesse contexto, este trabalho busca desenvolver um Sensor Virtual para o processo de laminação de aço utilizando os valores de vários parâmetros do processo com técnicas de Aprendizado de Máquinas (*Machine Learning*) para estimar a espessura da tira de aço após a cadeira de laminação. O desempenho do método proposto é validado usando dados industriais. A principal motivação para o desenvolvimento deste sensor virtual é o alto custo de manutenção e obsolescências do medidor de Raios X responsável pela medição da espessura das tiras de aço. A Figura 1 ilustra a estrutura resumida do processo de laminação de acabamento de tiras de aço.

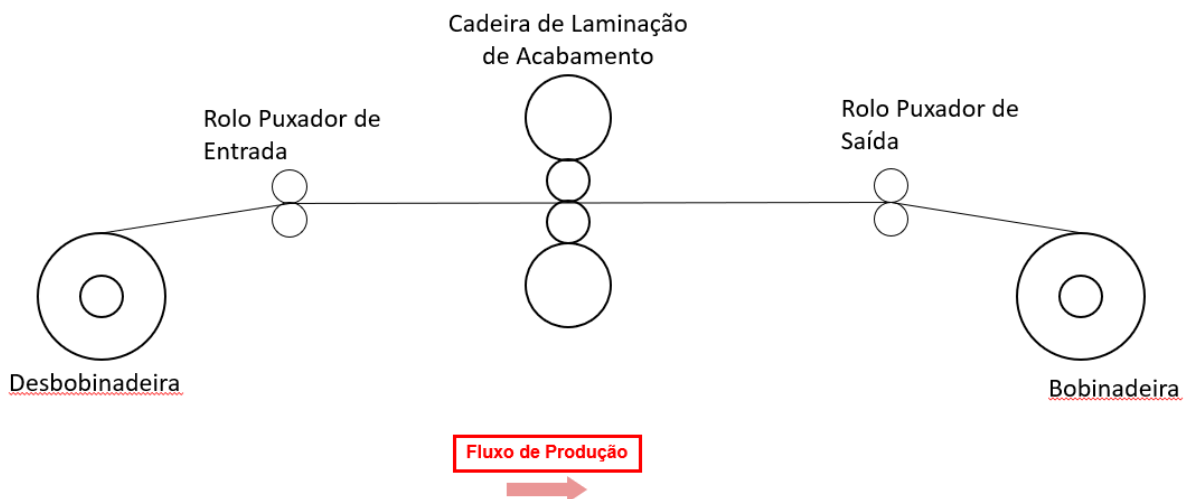


Figura 1: Estrutura resumida do laminador de acabamento.

O laminador de acabamento, ou de encruamento, promove um passe de acabamento no material laminado a quente, melhorando a qualidade de superfície, forma e dimensões das tiras, eliminando também o patamar de escoamento do material. As bobinas são carregadas no mandril da desbobinadeira e desenroladas para que sejam laminadas na cadeira de encruamento e enroladas no mandril da bobinadeira. Os rolos puxadores de entrada e saída são as referências topográficas da linha de passe da laminação.

Além disso, eles também fazem parte da malha de controle de alongamento. O valor medido de alongamento é obtido através da leitura de *encoders* acoplados aos rolos inferiores dos rolos puxadores de entrada e de saída. O valor setado é alcançado através da variação da força de laminação oferecida pela cadeira e tensão imposta ao material pela desbobinadeira e bobinadeira.

2 DESENVOLVIMENTO

Este trabalho consiste na aplicação de técnicas de Aprendizado Profundo para estimação da espessura de saída da tira de aço após o processo de laminação de encruamento. O método proposto é baseado na aquisição de dados da planta de

laminação de acabamento de tiras laminadas a quente da ArcelorMittal Tubarão e na aplicação de algoritmos específicos de aprendizagem de máquinas a fim de estimar, por regressão, a espessura de saída do laminador. A metodologia empregada neste trabalho é apresentada na Figura 2.

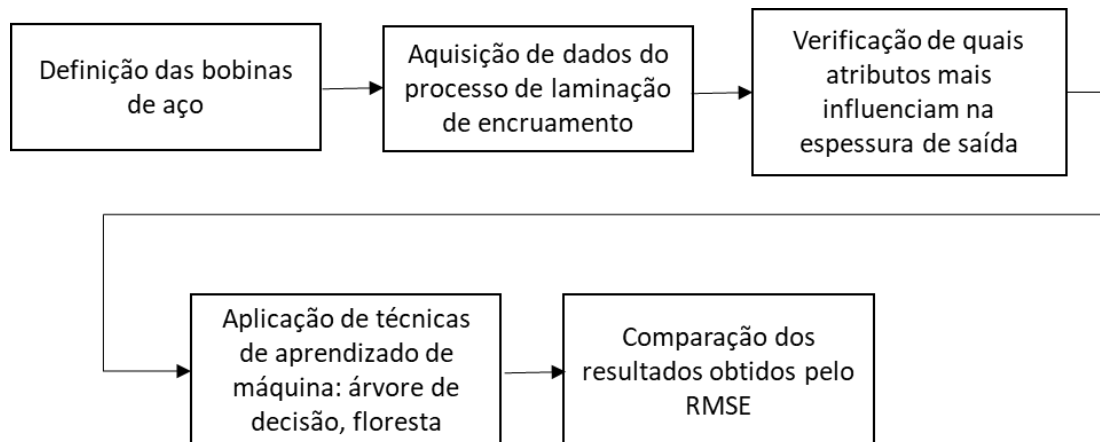


Figura 2. Metodologia empregada.

Para o desenvolvimento de sensores virtuais é necessário que alguns passos sejam seguidos, tais como, aquisição dos dados, seleção dos dados de entrada, escolha do modelo a ser empregado, treinamento e validação do modelo escolhido [14].

2.1 Aquisição dos Dados

Foram utilizadas, para realização dos testes, dez bobinas com diferentes características dimensionais (largura, espessura e comprimento), metalúrgicas (normas de aço) e mecânicas (limite de resistência do aço). Os dados obtidos são dos mesmos pares de cilindro de encosto e de trabalho do laminador para que também fosse apurada a importância da campanha dos cilindros de trabalho, especificamente. A Tabela 1 apresenta os atributos de entrada utilizados.

Tabela 1. Variáveis de entrada do banco de dados

Número	Parâmetro	Número	Parâmetro
01	Set Point da Força de Bending	19	Set Point da Tensão na Desbobinadeira
02	Pressão Bending Positiva	20	Tensão na Desbobinadeira
03	Pressão Bending Negativa	21	Set Point de Tensão na Bobinadeira
04	Set Point da Força de Laminação	22	Tensão na Bobinadeira
05	Força de Laminação	23	Largura da Tira
06	Força Diferencial de Laminação	24	Limite da Resistência do Aço
07	Abertura da Cadeira	25	Alongamento Ligado
08	Pressão na Cápsula Hidráulica no Lado da Operação	26	Set Point da Compensação de Força
09	Pressão na Cápsula Hidráulica no Lado Acionamento	27	Alongamento em modo de Tensão e Força Ligado
10	Sinal da Servo Válvula no Lado da Operação	28	Comprimento Restante na Desbobinadeira
11	Sinal da Servo Válvula no Lado Acionamento	29	Diâmetro do Cilindro Superior de Encosto

12	Feedback Interno na Servo Válvula no Lado Acionamento	30	Diâmetro do Cilindro Superior de Trabalho
13	Feedback Interno na Servo Válvula no Lado da Operação	31	Diâmetro do Cilindro Inferior de Trabalho
14	Velocidade de Referência do Laminador	32	Diâmetro do Cilindro Inferior de Encosto
15	Alongamento sobre a Tira de Aço	33	Espessura Mínima Aceita pelo Cliente
16	Set Point do Alongamento	34	Espessura Máxima Aceita pelo Cliente
17	Set Point do Ganho de Compensação do Alongamento	35	Campanha dos Cilindros de Trabalho
18	Alongamento		

Os dados do processo e de produção foram extraídos de bancos de dados específicos disponibilizados pela ArcelorMittal Tubarão e agrupados de maneira a atender aos requisitos dos algoritmos. Não foi necessário aplicar filtro nos dados de processo, o que atesta a confiabilidade dos instrumentos que compõem o sistema de controle da planta. O *software* utilizado nesse trabalho foi o Matlab, versão 2017b. Para analisar quais atributos de entrada tinham maior importância na variável de saída foi aplicado um algoritmo árvore de decisão.

2.2 Seleção dos Dados

Durante o processo de seleção das variáveis de entrada, notou-se que vários deles estão relacionados com a variável de saída. No entanto, algumas dessas variáveis estão mais ligadas com o valor da saída do que outras. Assim, ao invés de se utilizar todas as variáveis disponíveis, é interessante utilizar apenas aquelas que tenham maior influência no valor da variável de saída. Dessa maneira, pode-se reduzir o número de sensores reais de uma planta, o que reduz o seu custo e também se exige menos poder de processamento para a estimação da variável desejada. O método da árvore de decisão, que é um método de seleção de variáveis supervisionado, foi utilizado para correlacionar os 35 atributos de entrada com a saída. O resultado dessa correlação é apresentado na Figura 3.

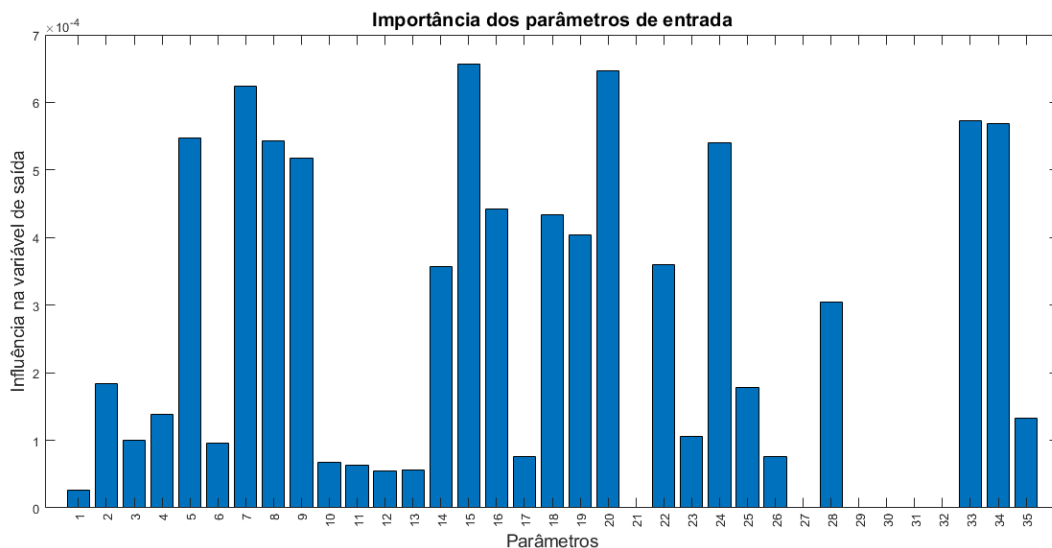


Figura 3. Importância dos parâmetros de entrada com relação à saída.

Ao observar a Figura 3, percebe-se que os parâmetros de processo com maior importância é o número 15 (alongamento aplicado sobre a tira de aço), o segundo mais importante é o parâmetro 20 (tensão do motor da desbobinadeira). As características com terceira, quarta e quinta maiores importâncias são, respectivamente, os atributos 7 (abertura da cadeira), 33 (espessura mínima especificada pelo cliente) e 34 (espessura máxima especificada pelo cliente). Os parâmetros 32 e 33 são utilizados para o julgamento da bobina quanto ao atendimento da especificação solicitada pelo cliente ao final do processamento. O sexto parâmetro é a força de laminação aplicada pela cápsula hidráulica da cadeira sobre a tira, que é indicado pelo número 5.

O alongamento é uma variável de processo referente à deformação imposta sobre a tira, no sentido do comprimento, cujo controle permite melhoria das qualidades superficial e mecânica do material que é processado e torna-se essencial no julgamento do material processado. Seu valor é predeterminado para o Controlador Lógico Digital (CLP) com base nas características mecânicas e dimensionais do material e também pode ser alterado pelo operador do processo. Seu valor máximo tem patamar de 3%.

Ao alongar o comprimento da tira, sua espessura de saída da cadeira de laminação também sofre variação, que é medida atualmente por um equipamento que tem como princípio a emissão de raios X e é a variável de saída estudada. O *set point* do alongamento é alcançado através da variação da força de laminação oferecida pela cadeira (parâmetro 5) e tensão imposta ao material pelos motores da desbobinadeira (parâmetro 20) e da bobinadeira. Esses resultados comprovam a relação entre os melhores preditores do algoritmo estudado.

Como os diâmetros dos cilindros superior e inferior de trabalho e de encosto não foram variados (parâmetros 29 a 32) no banco de dados, e, portanto, não influenciaram na espessura de saída. O *set point* da tensão da bobinadeira (parâmetro 21) e o alongamento em modo de tensão e força ligado (parâmetro 27) também não foram alterados para as bobinas analisadas. Nesse trabalho, foram utilizados todos os atributos de entradas com importância diferente de zero para a aplicação das técnicas de regressão.

3 RESULTADOS

Em todas as técnicas de regressão aplicadas foram utilizadas 70% das amostras totais do banco de dados para treinamento e validação e 30% para testes. Na partição dos dados destinados para treinamento e validação foi utilizada a validação do tipo *holdout*. Foram testados três métodos de regressão para validação do modelo do sensor virtual: Árvore de Decisão, Floresta de Decisão e Máquinas de Vetores Suporte com Regressão (SVR). Os resultados obtidos pelas técnicas estão apresentados a seguir. A Figura 4 apresenta a espessura real do processo medida pelo emissor de raios X das bobinas estudadas.

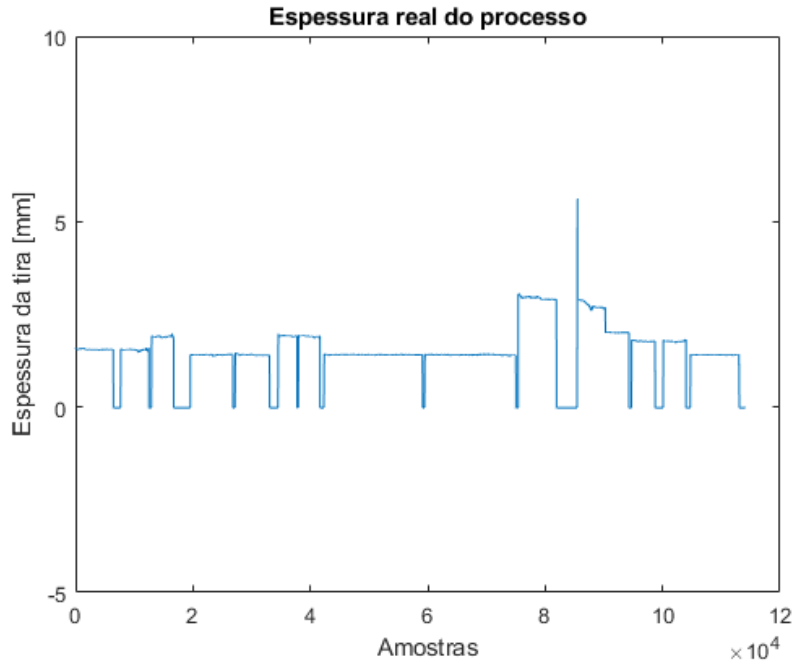


Figura 4. Espessura real do processo.

As Figuras 5 e 6 apresentam as espessuras estimadas e o erro, respectivamente, encontradas pelo método de árvore de decisão.




Figura 5. Espessura estimada pela árvore de decisão.




Figura 6. Erro apresentado pelo algoritmo da árvore de decisão.

A Figura 7 apresenta a aplicação de zoom da Figura 6 para melhorar a visualização do erro obtido pela árvore de decisão.

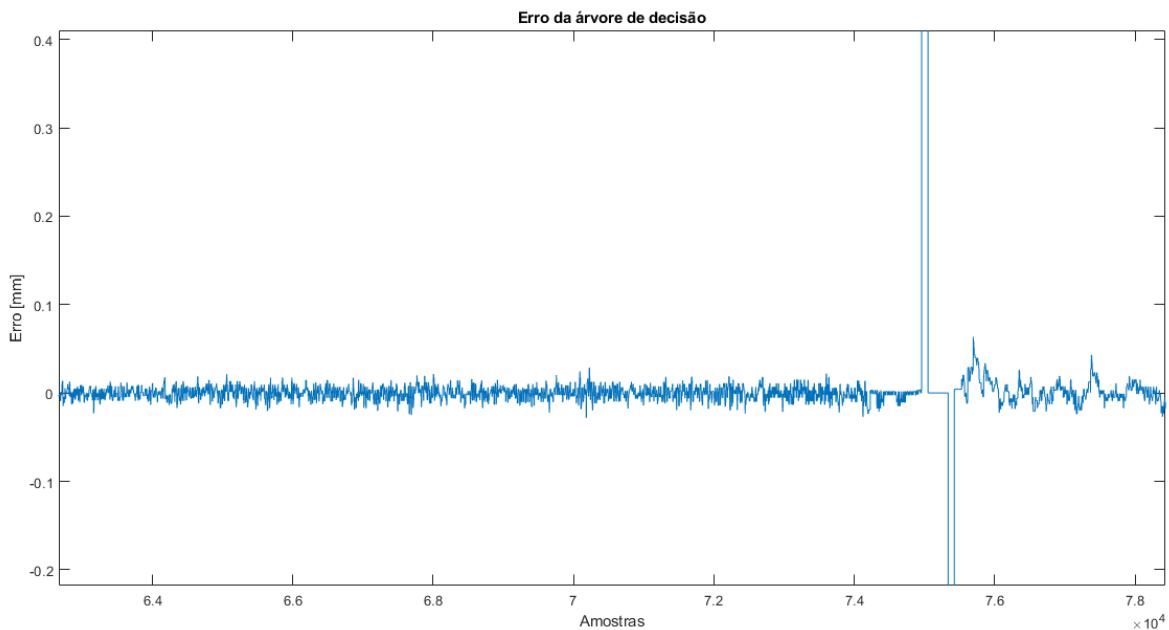


Figura 7. Aplicação de zoom no erro estimada pela árvore de decisão.

A Figura 8 apresenta a espessura estimada encontrada pelo método de floresta de decisão.

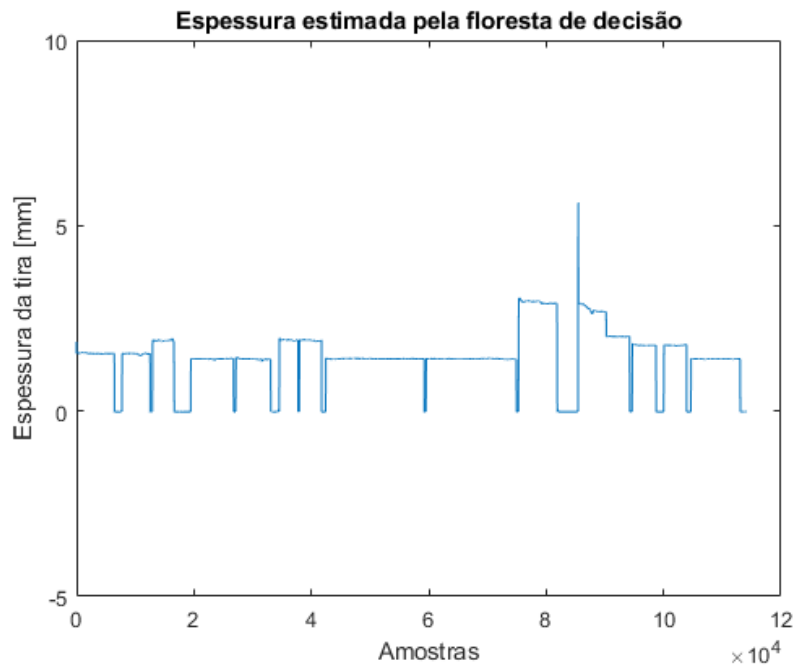


Figura 8. Espessura estimada pela floresta de decisão.

A Figura 9 ilustra o erro encontrado pelo método de floresta de decisão.

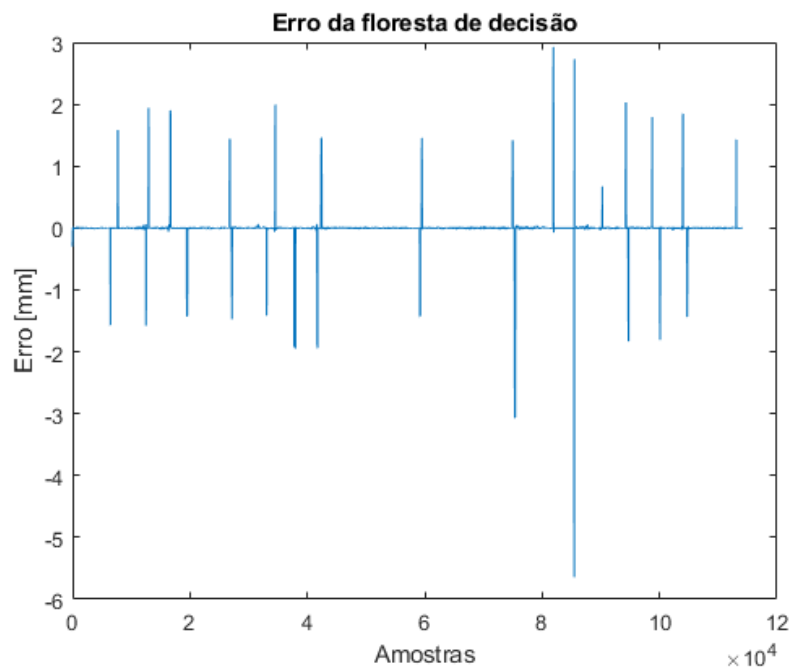


Figura 9. Erro apresentado pelo algoritmo da floresta de decisão.

Os picos nos valores dos erros apresentados nas Figuras 6 e 9 ocorrem na mudança de bobinas, no momento em que a medição é finalizada para uma bobina e, em seguida, iniciada para outra.

A Figura 10 apresenta a espessura estimada obtida pelo método SVR.

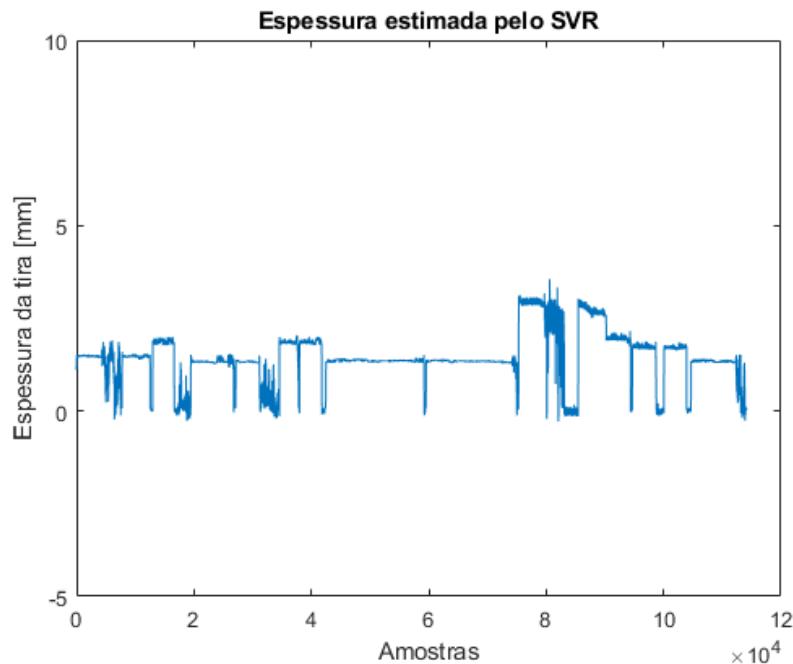


Figura 10. Espessura estimada pelo SVR.

A Figura 11 ilustra o erro encontrado pelo método SVR.

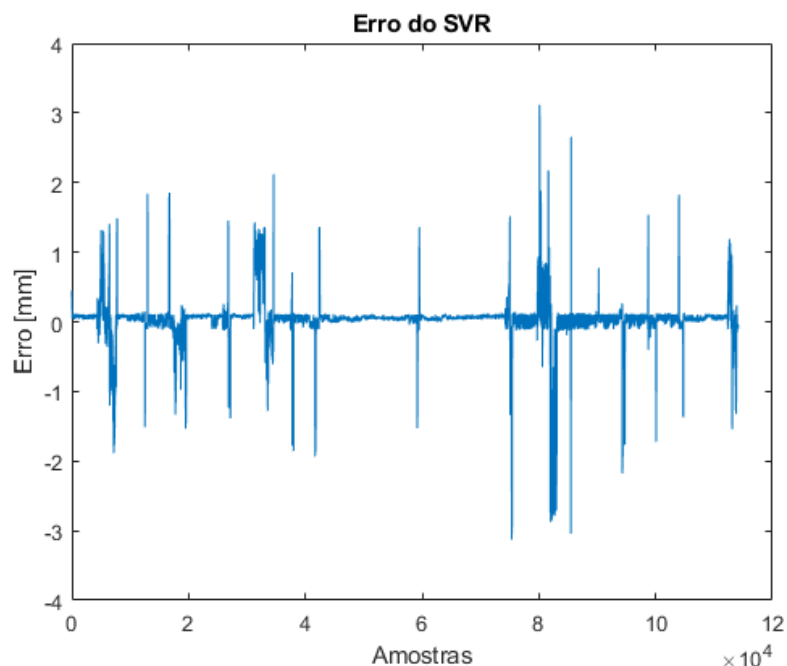


Figura 11. Erro apresentado pelo algoritmo SVR.

Pode-se observar que os métodos de árvore e floresta de decisão alcançaram valores bem similares aos dados reais de processos. Já o método SVR estimou a espessura com bastante variação. Para avaliar o desempenho dos três modelos de regressão aplicados no banco de dados foi adotada a raiz do erro quadrático médio (*Root Mean Square Error - RMSE*). A Equação 1 apresenta seu cálculo:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}} \quad (1),$$

onde n representa a quantidade total de amostras, \hat{y} a saída estimada e y a saída do processo real. A acurácia, medida pelo RMSE, obtida pelos três modelos de estimação é descrita na Tabela 2.

Tabela 2. Acurácia obtida pelos algoritmos de regressão implementados

Técnica de Regressão	Acurácia (RMSE)
Árvore de Decisão	0.0058
Floresta de Decisão	0.0060
SVR	0.3148

Pode-se observar que os melhores desempenhos, árvore de decisão e floresta de decisão, obtiveram resultado menor ou igual a 0,6%. Esses valores estão dentro da tolerância aceita pela especificação dos clientes em relação à variação da espessura. A precisão encontrada pelo método SVR se mostra com valor acima de 30%, fazendo com que ele esteja fora das tolerâncias permissíveis para o processo.

4 CONCLUSÃO

Este trabalho propôs a utilização de técnicas de Inteligência Artificial para realizar a modelagem de um sensor virtual e estimar a espessura de tiras de aço do laminador de acabamento da ArcelorMittal Tubarão. A base de dados utilizada para tal tarefa é composta por informações dos sensores reais existentes na planta de laminação, os quais fornecem 35 variáveis. A seleção das variáveis que estão mais relacionadas com a espessura da tira de aço foi feita através do método de Árvore de Decisão. Essas variáveis foram utilizadas para modelagem do sensor virtual, o que foi feito de três maneiras diferentes e os resultados apresentados por cada uma delas foram comparados. As técnicas utilizadas para realizar o modelo do sensor virtual foram: i) Árvore de Decisão com Regressão, ii) Floresta de Decisão e iii) SVR. Na etapa de testes, a espessura real da tira de aço foi comparada com a espessura estimada por cada um dos três métodos propostos e calculado o erro médio quadrático (RMSE) para cada uma delas. O RMSE apresentado pelo método SVR foi de 31,48%, enquanto os erros apresentados pela Árvore de Decisão e pela Floresta de Decisão foram de 0,58% e 0,60%, respectivamente. Pode-se concluir através da observação do baixo valor do RMSE apresentado pelas técnicas de regressão da Árvore de Decisão e da Floresta de Decisão que esses algoritmos atendem ao que foi proposto. Também demonstra que é possível a utilização de sensores virtuais para estimar a espessura de saída das tiras de aço do laminador de acabamento da ArcelorMittal Tubarão.

Agradecimentos

Os autores gostariam de agradecer à Gerência de Acabamento de Produtos da ArcelorMittal Tubarão pela disponibilização dos dados para a realização deste trabalho.

REFERÊNCIAS

- 1 D. Wang, J. Liu, and R. Srinivasan, "Data-driven soft sensor approach for quality prediction in a refining process," IEEE Transactions on Industrial Informatics, vol. 6, no. 1, pp. 11–17, Feb 2010.

- 2 A. Rother, M. Jelali, and D. Sffker, "A brief review and a first application of time-frequency-based analysis methods for monitoring of strip rolling mills," *Journal of Process Control*, vol. 35, pp. 65 – 79, 2015.
- 3 L. Fortuna, S. Graziani, and M. G. Xibilia, "Comparison of softsensor design methods for industrial plants using small data sets," *IEEE Transactions on Instrumentation and Measurement*, vol. 58, no. 8, pp. 2444–2451, Aug 2009.
- 4 P. Kadlec, R. Grbi, and B. Gabrys, "Review of adaptation mechanisms for data-driven soft sensors," *Computers & Chemical Engineering*, vol. 35, no. 1, pp. 1 – 24, 2011.
- 5 D. Schtz, A. Wannagat, C. Legat, and B. Vogel-Heuser, "Development of plc-based software for increasing the dependability of production automation systems," *IEEE Transactions on Industrial Informatics*, vol. 9, no. 4, pp. 2397–2406, Nov 2013.
- 6 M. Grbovic, W. Li, N. A. Subrahmanya, A. K. Usadi, and S. Vucetic, "Cold start approach for data-driven fault detection," *IEEE Transactions on Industrial Informatics*, vol. 9, no. 4, pp. 2264–2273, Nov 2013.
- 7 F. Souza and R. Arajo, "Online mixture of univariate linear regression models for adaptive soft sensors," *IEEE Transactions on Industrial Informatics*, vol. 10, no. 2, pp. 937–945, May 2014.
- 8 J. Gao, X. Yang, Y. A. W. Shardt, Y. Zhang, F. He, and C. Tong, "Soft sensor modeling based on pca and ls-svm for strip thickness in cold steel rolling mills," in *2017 Chinese Automation Congress (CAC)*, Oct 2017, pp. 3758–3763.
- 9 J. Zhu, Z. Ge, and Z. Song, "Robust semi-supervised mixture probabilistic principal component regression model development and application to soft sensors," *Journal of Process Control*, vol. 32, pp. 25–37, 08 2015.
- 10 Y. He, Y. Xu, Z. Geng, and Q. Zhu, "Soft sensor of chemical processes with large numbers of input parameters using auto-associative hierarchical neural network," *Chinese Journal of Chemical Engineering*, vol. 23, no. 1, pp. 138 – 145, 2015.
- 11 W. Yan, H. Shao, and X. Wang, "Soft sensing modeling based on support vector machine and bayesian model selection," *Computers & Chemical Engineering*, vol. 28, no. 8, pp. 1489 – 1498, 2004.
- 12 Z. X. Wang, Q. P. He, and J. Wang, "Comparison of variable selection methods for pls-based soft sensor modeling," *Journal of Process Control*, vol. 26, pp. 56 – 72, 2015.
- 13 Z. Sun, J. Zhao, Z. Shi, and S. Yu, "Soft sensing of magnetic bearing system based on support vector regression and extended kalman filter," *Mechatronics*, vol. 24, no. 3, pp. 186 – 197, 2014.
- 14 KADLEC, P.; GABRYS, B.; STRANDT, S. Data-driven Soft Sensors in the process industry. *Computers and Chemical Engineering*, v. 33, p. 795-814, 2009.