

INTELIGENCIA ARTIFICIAL NA LAMINAÇÃO A FRIO: SUBSTITUINDO SENSORES POR REDES NEURAIS ARTIFICIAIS. ODS (9.4)

Até 2030, modernizar a infraestrutura e reabilitar as indústrias para torná-las sustentáveis, com eficiência aumentada no uso de recursos e maior adoção de tecnologias e processos industriais limpos e ambientalmente adequados; com todos os países atuando de acordo com suas respectivas capacidades

Erik de Souza Couto (UNITAU)
Luis Fernando de Almeida (UNITAU)

Resumo

Este trabalho desenvolve e valida um modelo de inteligência artificial baseado em Redes Neurais Artificiais RNA para prever a tensão de estiramento da chapa durante o processo de laminação a frio. O objetivo principal é substituir os sensores físicos, que frequentemente enfrentam problemas de manutenção devido ao contato indireto com a chapa de aço, o que exige paradas no laminador e eleva os custos operacionais. Os dados utilizados para o treinamento e validação do modelo foram coletados de um sistema de Aquisição de Dados de Processo (PDA) e processados para garantir a integridade e a relevância das variáveis críticas. Durante o pré-processamento, técnicas como normalização e codificação de variáveis categóricas foram aplicadas. A biblioteca TensorFlow, junto com a API Keras, foi utilizada para construir o modelo de RNA. O modelo foi treinado usando dados históricos de um mês de operação e validado com dados de dias diferentes para assegurar a generalização dos resultados e evitar problemas de vazamento de dados. A avaliação final do modelo indicou um coeficiente de determinação (R^2) de 0,84, demonstrando uma alta precisão nas previsões de tensão. Esses resultados mostram a viabilidade de substituir os sensores físicos por um sistema preditivo baseado em RNA. Além de ser uma solução que auxilia a sustentabilidade, a substituição dos sensores físicos por um modelo preditivo contribui para a redução do consumo de materiais e energia, uma vez que diminui a necessidade de frequentes intervenções de manutenção e substituição de componentes. Com menos paradas no processo de laminação, há uma redução no desperdício de recursos e na geração de resíduos industriais. Adicionalmente, a eficiência operacional aprimorada implica em um menor consumo de energia durante o processo produtivo, o que, por sua vez, contribui para a redução das emissões de carbono. Assim, este trabalho não só melhora a eficiência e a rentabilidade das operações industriais, mas também promove práticas mais sustentáveis e responsáveis do ponto de vista ambiental.

Palavras-chave: Redes Neurais Artificiais; Laminação a Frio; Previsão de tensão; Sustentabilidade Operacional; Eficiência Operacional.

Introdução

A laminação a frio (Figura 1) é um processo crucial na indústria siderúrgica, responsável pela redução da espessura de chapas de aço em temperatura ambiente. As chapas produzidas são amplamente utilizadas em diversas aplicações, como embalagens de aço, telhas zincadas e lataria automobilística, onde a precisão e a qualidade do material são fundamentais. Para garantir esses padrões, é essencial o monitoramento contínuo da tensão de estiramento da chapa durante o processo de laminação. Tradicionalmente, este monitoramento é realizado por meio de sensores físicos, mais especificamente por células de carga Figura 2, que, apesar de sua importância, apresentam desafios significativos, como desgaste devido ao contato indireto com o material e a necessidade de paradas frequentes para manutenção e substituição.

Figura 1: Laminador de tiras a frio



Fonte: Couto(2024)

Figura 2: Célula de carga responsável pela medição de tensão da chapa



Fonte: Couto (2024).

O principal problema associado ao uso desses sensores é o impacto negativo nas operações do laminador, uma vez que as manutenções corretivas exigem a interrupção do processo produtivo, resultando em perda de tempo, aumento dos custos operacionais e redução da eficiência produtiva. Além disso, a necessidade de substituir regularmente esses sensores gera um consumo constante de materiais e energia, contribuindo para o aumento dos resíduos industriais e das emissões de carbono.

Diante desse cenário, justifica-se a busca por soluções que possam não apenas manter, mas melhorar a precisão do monitoramento da tensão sem os inconvenientes associados aos sensores físicos. A substituição desses sensores por um modelo preditivo baseado em inteligência artificial, especificamente Redes Neurais Artificiais RNA, surge como uma alternativa promissora. Além de reduzir a dependência de componentes físicos sujeitos a desgaste, tal solução pode aumentar a disponibilidade do laminador, reduzir os custos com manutenção e contribuir para práticas industriais mais sustentáveis.

Revisão da literatura

Os sensores responsáveis pela medição da tensão da tira desempenham um papel fundamental nos laminadores de tiras a frio, garantindo tanto a qualidade do produto quanto a estabilidade operacional. A medição e o controle da tensão são essenciais para manter as propriedades desejadas das tiras, além de evitar problemas como defeitos de planicidade e arrebentamentos (Hathaway & Mohler, 1937). Esses sensores contribuem significativamente para a otimização do processo, permitindo uma melhor qualidade de superfície da tira (Rumyantsev et al., 2021). Assim, os sistemas de controle e medição de tensão tornam-se indispensáveis para a eficiência e eficácia geral dos laminadores de tiras a frio, desempenhando um papel crucial nas operações modernas de laminação (An et al., 2001).

A ausência de medição da tensão da tira em laminadores pode afetar significativamente a operação, resultando em variações de tensão, redução da qualidade do produto e possíveis danos ao equipamento (Jeong-Uk Lee et al., 2000; Pittner & Simaan, 2019). Isso ressalta a importância dos sensores de tensão no contexto operacional dos laminadores.

Historicamente, os métodos tradicionais de medição da tensão da tira em laminadores de tiras a frio evoluíram consideravelmente ao longo do tempo. As primeiras abordagens incluíam sistemas baseados em contato, que apresentavam o risco de arranhar a superfície da tira e exigiam manutenção extensiva (Spreitzhofer et al., 2005). Um avanço significativo foi o desenvolvimento de um tensiômetro (medidor de tensão da tira) pioneiro na década de 1930, que fornecia indicação contínua de tensão (Hathaway & Mohler, 1937). Na década de 1940, modelos teóricos começaram a ser propostos para calcular a força e as tensões de laminação (Bland & Ford, 1948), enquanto, posteriormente, análises mais sofisticadas incorporaram tanto as deformações elásticas das tiras e dos rolos quanto as deformações plásticas e tensões aplicadas (Jortner et al., 1960). Abordagens modernas incluem a estimativa da tensão da tira utilizando observadores baseados em equações diferenciais (Ruiz C. & Sbarbaro H., 1997) e algoritmos de aprendizado de máquina (Wang et al., 2007).

Ao longo dessa evolução, diversas técnicas de modelagem foram aplicadas para estudar a tensão da tira em processos de laminação a frio. Os métodos de elementos finitos (FE) têm sido amplamente utilizados para analisar os

comportamentos mecânicos e térmicos de tiras e rolos (Kim et al., 2003; Koohbor & Moaven, 2017). Métodos mais recentes, que utilizam aprendizado de máquina, especialmente redes neurais, têm sido empregadas para prever o arrebitamento de tiras a partir de dados de séries temporais (Chen et al., 2020).

As redes neurais, em particular, têm se mostrado promissoras na superação dos desafios relacionados à previsão de tensão de tiras e em outras tarefas associadas aos laminadores. Elas podem melhorar a precisão da previsão da força de laminação em 30 a 50% em comparação com os modelos matemáticos tradicionais (Cho et al., 1997). De fato, as redes neurais são altamente eficazes na gestão de relações não lineares e no processamento de dados de alta dimensionalidade na produção de aço (Kim et al., 2001; Schlang et al., 1999). Atualmente, elas têm sido aplicadas com sucesso a diversos aspectos do controle de laminadores, como a previsão do tempo de desbaste e acabamento (Colla et al., 2010), previsão de consumo de energia (de Oliveira et al., 2020) e previsão de propriedades mecânicas (Jones et al., 2005).

Os modelos preditivos, por sua vez, oferecem várias vantagens em relação às medições diretas dos sensores em diversas aplicações. Eles podem melhorar a qualidade dos dados ao combinar leituras de sensores com previsões de modelos, o que reduz erros e aumenta a precisão (de Oliveira et al., 2021). Além disso, esses modelos podem funcionar como “sensores virtuais”, estimando variáveis difíceis de serem medidas diretamente (Chien et al., 1997). Essa abordagem pode, inclusive, reduzir o número de sensores físicos necessários, diminuindo os custos e permitindo o monitoramento em áreas inacessíveis (Stewart et al., 2017). Adicionalmente, os modelos preditivos possuem a capacidade de antecipar futuras leituras, o que representa uma vantagem estratégica na operação dos laminadores.

Método

A pesquisa possui caráter experimental e aplicado, focando no desenvolvimento e validação de um modelo de RNA para prever a tensão de estiramento da chapa metálica durante o processo de laminação a frio. O modelo foi validado utilizando dados reais adquiridos pelos sensores físicos durante a operação do laminador de tiras a frio.

Durante a pesquisa, especialistas da área identificaram as variáveis com maior impacto na tensão de estiramento da chapa, conforme apresentado na

Tabela 1. Para a aquisição dos dados de processo identificados pelos especialistas, foi instalado um sistema de Aquisição de Dados de Processo PDA da empresa IBA, em um microcomputador que se comunicava diretamente com o Controlador Lógico Programável PLC do laminador, permitindo a coleta de dados em tempo real. Todas as variáveis consideradas importantes para o modelo foram coletadas ao longo de um mês de operação, com uma periodicidade de 10 ms entre as coletas.


Tabela 1: Variáveis para modelo de predição de tensão

VARIÁVEIS PARA MODELO DE PREDIÇÃO DE TENSÃO
GRAU DO AÇO
TENSÃO UNITÁRIA DA CADEIRA 4
REDUÇÃO DA CADEIRA 4
FORÇA TOTAL CADEIRA 4
CORRENTE DA CADEIRA 4
VELOCIDADE DA CADEIRA 4
VELOCIDADE DA CADEIRA 5
REDUÇÃO DA CADEIRA 5
FORÇA TOTAL DA CADEIRA 5
ESPESSURA DE SAÍDA
CORRENTE DA CADEIRA 5

Fonte: Couto (2024)

Após um mês de coleta de dados, foi verificado que apenas o grau de aço 2370, característica que define a dureza da chapa, apresentava representatividade suficiente para o desenvolvimento de um modelo de inteligência artificial. Os outros tipos de chapa, por não serem produzidos com a mesma frequência, não possuíam registros abrangentes de todas as suas variáveis, como largura, espessura de entrada e espessura de saída, conforme ilustrado na Figura 3 e 4.


Figura 3: Número de amostras por grau do aço.



Fonte: Couto (2024)

Pela distribuição dos dados ficou claro que durante o mês observado só conseguimos dados suficientes para duas espessuras de saída 0,17 mm e 0,19 mm. Por isso, o modelo foi treinado somente nessas espessuras, pois se a maioria dos dados se concentram em espessuras específicas, o modelo pode ficar enviesado para essas espessuras, e o desempenho pode ser ruim para espessuras menos representadas.

Figura 4: Distribuição da espessura de saída



Fonte: Couto (2024)

Coleta e Preparação de Dados

Para o desenvolvimento do modelo de inteligência artificial, os dados foram coletados e pré-processados a partir de arquivos de texto que continham as variáveis para a previsão da tensão de estiramento da chapa durante o processo de laminação a frio. Os dados foram extraídos do sistema PDA. Estes dados foram armazenados em arquivos de formato .dat e posteriormente exportados para .txt e organizados em uma estrutura de pastas.

Organização e Leitura dos Dados

Um script em Python foi desenvolvido para automatizar a leitura e organização dos dados. Uma função percorre recursivamente todas as subpastas dentro do diretório especificado, buscando arquivos .txt. Para cada arquivo encontrado, outra função é chamada para realizar o pré-processamento dos dados. Este processo inclui:

Leitura dos Dados: Os dados são lidos utilizando a biblioteca pandas, com a configuração adequada para separadores e codificação.

Tratamento de Valores Inválidos: Valores como #INF são substituídos por None e, em seguida, todas as linhas contendo valores ausentes são excluídas do dataset.

Substituição de Separadores Decimais: Vírgulas são substituídas por pontos, para garantir a correta interpretação dos números como valores de ponto flutuante.

Conversão dos Dados: Finalmente, todos os valores são convertidos para o tipo float para garantir consistência nos cálculos subsequentes.

Os dados pré-processados de cada arquivo são então concatenados em um único DataFrame, que agrega todas as informações coletadas ao longo de um mês de operação.

Divisão dos Dados e Pré-processamento Adicional

Os dados utilizados no treinamento do modelo foram coletados ao longo de um mês por meio do software IbaPDA, responsável pela Aquisição de Dados de Processo (PDA). Durante esse período, foram capturadas medições a cada 5 segundo, resultando em um total de (312.112 amostras, após filtragem dos dados) e 9 variáveis no conjunto de dados de treinamento, todas relacionadas ao processo

de laminação, como tensão unitária, força e corrente nas cadeiras 4 e 5, além de velocidade e espessura de saída

Desenvolvimento do Modelo

O modelo de Rede Neural Artificial RNA foi construído utilizando a biblioteca TensorFlow e a API Keras. O modelo utilizado foi uma Rede Neural Multicamadas (MLP - Multi-Layer Perceptron):

Arquitetura da Rede Neural:

O modelo é composto por três camadas densas:

Primeira camada: 18 neurônios, função de ativação ReLU.

Segunda camada: 9 neurônios, função de ativação ReLU, com regularização L2.

Terceira camada: 5 neurônios, função de ativação ReLU, com regularização L2.

Saída: uma camada com 1 neurônio, para prever o valor contínuo da tensão.

A rede usa regularização L2 nas camadas intermediárias para evitar overfitting.

Compilação e Treinamento:

Otimizador: RMSprop.

Função de perda: Erro Quadrático Médio (MSE).

Métrica: Mean Absolute Percentage Error (MAPE).

O modelo foi treinado com os dados pré-processados e o conjunto de validação foi utilizado para monitorar o desempenho durante o treinamento. Um callback de parada antecipada EarlyStopping foi configurado para interromper o treinamento caso a perda no conjunto de validação não melhorasse após 10 épocas, garantindo que o modelo mantivesse as melhores configurações de pesos.

Dados de Treinamento e Validação:

Após o treinamento inicial do modelo de RNA, foi realizada a validação utilizando um conjunto de dados separado para avaliar o desempenho do modelo em dados não vistos durante o treinamento. Os dados de validação foram extraídos de um dia aleatório e processados de maneira similar aos dados de treinamento.

A normalização dos dados foi realizada usando MinMaxScaler para garantir que todas as variáveis estejam em uma mesma escala.

Para validar o modelo, foram coletados dados de dias distintos daqueles utilizados no treinamento, garantindo que a validação não sofresse com o problema de vazamento de dados e, assim, evitando resultados de precisão enganosos.

Um dos dias utilizados para validação contou com 1736 dados para validação, indicando que, apesar de o conjunto de validação ter sido menor, ele foi variado o suficiente para garantir que o modelo fosse testado em condições diferentes.


Assim como nos dados de treinamento, apenas registros que atendiam a condições específicas como o grau do aço 2370 e as espessuras de saídas 0,17 e 0,19 foram mantidas, garantindo que o modelo fosse avaliado em condições comparáveis às do treinamento.

Resultados e Discussão

A análise da distribuição das espessuras de laminação e grau do aço, bem como de outras variáveis críticas, indicou que a maioria dos dados estava concentrada em espessuras específicas, como 0,17 mm e 0,19 mm, sugerindo que o modelo treinado seria mais confiável para essas espessuras. A limitação do conjunto de dados a essas espessuras específicas permitiu um ajuste fino do modelo, aumentando a precisão das previsões para essas condições.

O modelo final alcançou um coeficiente de determinação (R^2) de 0,92 Figura 5, quando correlacionado os dados de treinamento e os dados previstos pelo modelo.

Figura 5: Dados de treinamento e predição.




Fonte: Couto (2024)

Os valores em laranja da Figura 5 são os dados previsto pelo modelo e os dados em azul são os valores medidos pelo sensor físico, após filtro para reduzir o ruído proveniente do sensor.

Com relação aos dados de validação, ou seja, dados de dias aleatórios que não fizeram parte do treinamento, o modelo alcançou um coeficiente de determinação (R^2) de 0,84 demonstrando uma alta correlação entre as previsões do modelo e as medições reais Figura 6.

Figura 6: Dados de validação azul e predição em laranja.




Fonte: Couto (2024)

Ao avaliar os resultados do modelo preditivo de tensão desenvolvido, é importante considerar a maneira como os dados de tensão são armazenados e lidos pelo sistema de medição. Na Figura 7, é apresentado o comportamento dos dados de tensão conforme registrados pelo sensor, sem a aplicação de filtros adicionais. Esses dados exibem uma variação natural, com flutuações que, em média, permanecem dentro de uma faixa de 15%.

O modelo de Redes Neurais Artificiais RNA foi treinado para prever a tensão de estiramento com base nos dados processados e, notavelmente, as previsões feitas pelo modelo se mantêm dentro dessa faixa de variação natural dos dados de entrada. Isso significa que o modelo consegue capturar e reproduzir com precisão as oscilações inerentes ao processo de laminação, sem introduzir desvios significativos que possam ser atribuídos a erros de modelagem.

Esse resultado é particularmente relevante porque, em processos industriais como a laminação a frio, é esperado que os sensores apresentem variações devido as condições operacionais.

Figura 7: Oscilação natural do sensor de tensão fica em torno de 15%.



Fonte: Couto(2024)

Durante a análise dos resultados do modelo preditivo, foi observado que o desempenho do modelo é significativamente melhor para prever dados que são mais próximos dos dados utilizados no treinamento. Essa observação reflete um comportamento comum em modelos de aprendizado de máquina, onde o modelo tende a ser mais preciso em situações que estão dentro do escopo do que foi aprendido durante o treinamento.


Especificamente, o modelo desenvolvido para prever a tensão de estiramento durante o processo de laminação a frio mostrou-se mais eficaz ao lidar com dados que apresentam características mais próxima às dos dados utilizados para treiná-lo. Isso ocorre porque o modelo foi otimizado para reconhecer e reproduzir padrões específicos encontrados nos dados de treinamento. Quando o modelo é exposto a novos dados que compartilham esses padrões, ele consegue realizar previsões com alta precisão.

Por outro lado, conforme os dados de entrada se distanciam das condições encontradas no treinamento, seja em termos de variáveis operacionais, características do material, ou outras condições externas, o modelo pode ter mais dificuldade em generalizar e manter o mesmo nível de precisão. Isso se deve ao fato de que o modelo foi ajustado para os padrões específicos observados nos dados de treinamento e, portanto, pode não ter sido exposto a variabilidades que ocorrem fora desse intervalo.

Essa observação destaca a importância de um conjunto de dados de treinamento diversificado e abrangente, que reflita de maneira adequada as condições sob as quais o modelo será aplicado. No entanto, mesmo com um conjunto de dados variado, é natural que o modelo funcione melhor em cenários semelhantes aos já vistos. Isso reforça a necessidade de monitorar continuamente o desempenho do modelo e, se necessário, retreiná-lo ou ajustar o conjunto de dados de treinamento para incluir novos padrões que possam surgir na operação real.

A Figura 8 mostra o resultado para dados com um ano de diferença entre os dados usados para o treinamento do modelo e os dados para predição e o coeficiente de (R^2) cai para 0,6.

Figura 8: Dados de validação com um ano de diferença dos dados de treinamento.



Fonte: Couto(2024).

O modelo, mesmo treinado com dados obtidos em um período relativamente curto, foi capaz de prever com precisão as condições operacionais dentro do escopo dos dados de treinamento. Observou-se, no entanto, que o desempenho do modelo diminui conforme os dados de entrada se distanciam das condições vistas durante o treinamento.

Essa diminuição no desempenho levanta uma questão importante sobre a duração ideal do período de coleta de dados para treinamento do modelo. Se os dados de treinamento forem coletados ao longo de um período maior, é possível que o modelo desenvolva uma maior resiliência às variações observadas, tornando-

o mais robusto e eficaz em condições operacionais variáveis. Especificamente, um período de coleta de dados superior a um mês pode abranger uma maior diversidade de condições operacionais, incluindo mudanças sazonais, variações nos lotes de material e outros fatores que influenciam a tensão de estiramento.

O treinamento do modelo com dados que representem um período maior permitiria ao modelo captar padrões mais complexos e flutuações que ocorrem naturalmente ao longo do tempo. Isso pode reduzir a necessidade de retreinamento, uma vez que o modelo estaria melhor equipado para lidar com novas condições que surgem fora do intervalo de tempo original utilizado para treinamento. Além disso, um período de treinamento estendido poderia ajudar a suavizar as oscilações nos dados, resultando em previsões mais estáveis e confiáveis.

Entretanto, é importante considerar o trade-off entre a quantidade de dados coletados e o tempo necessário para o processamento e treinamento do modelo. Embora um maior volume de dados possa aumentar a robustez do modelo, ele também pode aumentar a complexidade, o tempo de processamento, e potencialmente reduzir a precisão para predição de dados muito próximos aos utilizados no treinamento. Nesse sentido, o modelo desenvolvido já demonstrou benefícios claros na substituição temporária dos sensores físicos. No entanto, a exploração de períodos de coleta de dados mais longos pode oferecer melhorias adicionais, como a redução das variações observadas, aumentando assim a longevidade e a precisão do modelo em cenários industriais.

Esse impacto é ainda mais relevante quando se considera o custo significativo relacionado às células de carga nas cadeiras de laminação. Cada cadeira utiliza duas células de carga, com um custo unitário de R\$ 153.526,73 (Última cotação). No laminador em que o trabalho foi realizado, composto por cinco cadeiras, o investimento total em células de carga é considerável. Além disso, uma substituição emergencial de uma célula de carga gera um custo de R\$ 15.942,00 por evento, considerando as 6 horas de parada necessárias, ao custo de R\$ 2.657,00 por hora parada. Com a estimativa de três paradas emergenciais por ano, o custo anual de interrupções não planejadas chega a R\$ 47.826,00.

Ao eliminar a necessidade de paradas emergenciais, o modelo preditivo desenvolvido possibilita que o laminador continue operando até uma parada planejada. Isso não apenas evita as interrupções inesperadas, mas também proporciona maior controle sobre o processo de produção. Embora o modelo não substitua definitivamente as células de carga, ele possibilita uma operação contínua até o próximo intervalo de manutenção programada, evitando custos elevados e oferecendo uma economia significativa.

Conclusão

O desenvolvimento de um modelo preditivo baseado em RNA para a previsão da tensão de estiramento durante o processo de laminação a frio representa um avanço significativo na eficiência operacional. Este modelo mostrou-se altamente eficaz em substituir os sensores físicos por um determinado período, permitindo que a operação do laminador continue sem interrupções indesejadas para manutenção. Com a capacidade de redução notável nas paradas de produção, aumentando a disponibilidade do equipamento e otimizando os custos operacionais.

Os resultados demonstram que o modelo é capaz de prever a tensão de forma precisa, mantendo as previsões dentro da faixa de variação natural registrada pelos sensores. Esse alto nível de precisão não apenas valida a robustez do modelo, mas também proporciona uma camada adicional de segurança e confiabilidade no processo de laminação a frio, contribuindo diretamente para a qualidade do produto final.

Outro ponto positivo é a flexibilidade que o modelo oferece. Ao substituir os sensores físicos, ele permite que a produção continue em situações onde, de outra forma, seria necessário parar o equipamento para manutenção. Essa capacidade de postergar paradas planejadas traz um impacto positivo direto na produtividade e nos indicadores de desempenho.

Entretanto, é importante destacar que, com o passar do tempo, e à medida que as condições operacionais mudam, o modelo pode requerer ajustes. Observou-se que o desempenho do modelo é melhor quando os dados de previsão são mais próximos considerando a variável tempo aos dados que foram submetidos ao treinamento do modelo. Por isso, para garantir a eficácia contínua, é recomendado que o modelo seja retreinado periodicamente, incorporando novos dados que

reflitam as condições atuais do processo ou seja feito um treinamento com dados de processos de um período mais longo.

Em conclusão, o modelo desenvolvido proporciona uma ferramenta poderosa e inovadora para a indústria de laminação a frio. Sua capacidade de substituir sensores físicos, melhorar a continuidade operacional e reduzir custos o torna uma solução valiosa, posicionando-se como uma peça-chave na modernização e otimização dos processos industriais.

Referências

HATHAWAY, C. M.; MOHLER, M. Tension measurement and control in cold-strip mills. *Electrical Engineering*, [S. l.], v. 56, n. 7, p. 780-784, 1937. DOI: 10.1109/ee.1937.6538990. Disponível em: <https://doi.org/10.1109/ee.1937.6538990>. Acesso em: 13 ago. 2024.

RUMYANTSEV, M.; ZAVALISHCHIN, A. N.; ESIPOVA, O. N. Justification of strip tension in the cold rolling mill digital twin. *Chernye Metally*, [S. l.], v. 2021, n. 11, p. 123-127, 2021. DOI: 10.17580/chm.2021.11.10. Disponível em: <https://doi.org/10.17580/chm.2021.11.10>. Acesso em: 14 ago. 2024.

AN, B. J.; PARK, Sung-Han; LEE, M.; et al. Tension control system for hot strip mills. In: *IEEE INTERNATIONAL SYMPOSIUM ON INDUSTRIAL ELECTRONICS*, 2001, Pusan. *Proceedings...* [S. l.]: IEEE, 2001. p. 1050-1055. DOI: 10.1109/ISIE.2001.931919. Disponível em: <https://doi.org/10.1109/ISIE.2001.931919>. Acesso em: 16 ago. 2024.

LEE, Jeong-Uk; CHOI, C.; HYUN, D.; et al. On-line compensation of friction loss for continuous strip processing line. In: *IEEE INDUSTRY APPLICATIONS CONFERENCE*, 2000, Roma. *Conference Record of the 2000 IEEE Industry Applications Conference. Thirty-Fifth IAS Annual Meeting and World Conference on Industrial Applications of Electrical Energy*. [S. l.]: IEEE, 2000. p. 1450-1454. DOI: 10.1109/IAS.2000.883199. Disponível em: <https://doi.org/10.1109/IAS.2000.883199>. Acesso em: 16 ago. 2024.

PITTNER, J.; SIMAAN, M. Improving the availability of tandem hot metal strip rolling: the use of fault-tolerant techniques with virtual rolling. *IEEE Industry Applications*, [S. l.], v. 55, n. 4, p. 4567-4574, 2019. DOI: 10.1109/MIAS.2018.2875216. Disponível em: <https://doi.org/10.1109/MIAS.2018.2875216>. Acesso em: 16 ago. 2024.

SPREITZHOFFER, G.; DUEMMER, A.; TOMASIC, M. SI-FLAT contactless flatness measurement for cold rolling mills and processing lines. *Revue De Metallurgie-cahiers D Informations Techniques*, [S. l.], v. 102, n. 9, p. 765-771, 2005. DOI: 10.1051/METAL:2005176. Disponível em: <https://doi.org/10.1051/METAL:2005176>. Acesso em: 16 ago. 2024.

BLAND, D.; FORD, H. The calculation of roll force and torque in cold strip rolling with tensions. *Proceedings of the Institution of Mechanical Engineers*, [S. l.], v. 159, n. 1,

p. 144-163, 1948. DOI: 10.1243/PIME_PROC_1948_159_015_02. Disponível em: https://doi.org/10.1243/PIME_PROC_1948_159_015_02. Acesso em: 16 ago. 2024.

JORTNER, D.; OSTERLE, J. F.; ZOROWSKI, C. An analysis of cold strip rolling. International Journal of Mechanical Sciences, [S. l.], v. 2, n. 4, p. 261-278, 1960. DOI: 10.1016/0020-7403(60)90003-5. Disponível em: [https://doi.org/10.1016/0020-7403\(60\)90003-5](https://doi.org/10.1016/0020-7403(60)90003-5). Acesso em: 16 ago. 2024.

RUIZ C., J.; SBARBARO H., D. Estimating the strip tension in multi-drive systems. In: INTERNATIONAL CONFERENCE ON INDUSTRIAL ELECTRONICS, CONTROL, AND INSTRUMENTATION, 23., 1997, New Orleans. Proceedings of the IECON'97 23rd International Conference on Industrial Electronics, Control, and Instrumentation. [S. l.]: IEEE, 1997. p. 1450-1455. DOI: 10.1109/IECON.1997.668529. Disponível em: <https://doi.org/10.1109/IECON.1997.668529>. Acesso em: 16 ago. 2024.

WANG, J. S.; JIANG, Z. Y.; WANG, G.; et al. A method to improve model calculation accuracy of process control in tandem cold mills. In: IEEE CONFERENCE ON INDUSTRIAL ELECTRONICS AND APPLICATIONS, 2., 2007, Harbin. Proceedings... [S. l.]: IEEE, 2007. p. 1730-1735. DOI: 10.1109/ICIEA.2007.4318919. Disponível em: <https://doi.org/10.1109/ICIEA.2007.4318919>. Acesso em: 16 ago. 2024.

KIM, T. H.; LEE, Won-Ho; HWANG, S. An integrated FE process model for the prediction of strip profile in flat rolling. ISIJ International, [S. l.], v. 43, n. 12, p. 1947-1956, 2003. DOI: 10.2355/ISIJINTERNATIONAL.43.1947. Disponível em: <https://doi.org/10.2355/ISIJINTERNATIONAL.43.1947>. Acesso em: 16 ago. 2024.

KOOHBOR, B.; MOAVEN, Kh. Finite-element modeling of thermal aspects in high speed cold strip rolling. Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture, [S. l.], v. 231, n. 6, p. 1011-1021, 2017. DOI: 10.1177/0954405415592198. Disponível em: <https://doi.org/10.1177/0954405415592198>. Acesso em: 16 ago. 2024.

CHEN, Zheyuan; LIU, Ying; PACKIANATHER, M.; et al. Multi-faceted modelling for strip breakage in cold rolling using machine learning. International Journal of Production Research, [S. l.], v. 58, n. 20, p. 6291-6304, 2020. DOI: 10.1080/00207543.2020.1812753. Disponível em: <https://doi.org/10.1080/00207543.2020.1812753>. Acesso em: 16 ago. 2024.

CHO, S.; CHO, Yongjung; YOON, Sungchul. Reliable roll force prediction in cold mill using multiple neural networks. IEEE Transactions on Neural Networks, [S. l.], v. 8, n. 4, p. 943-953, 1997. DOI: 10.1109/72.595885. Disponível em: <https://doi.org/10.1109/72.595885>. Acesso em: 16 ago. 2024.

SCHLANG, M.; FELDKELLER, Björn; RUNKLER, T.; et al. Neural computation in steel industry. In: EUROPEAN CONTROL CONFERENCE, 1999, Karlsruhe. Proceedings... [S. l.]: IEEE, 1999. p. 1745-1750. DOI: 10.23919/ECC.1999.7099772. Disponível em: <https://doi.org/10.23919/ECC.1999.7099772>. Acesso em: 16 ago. 2024.

COLLA, V.; VANNUCCI, M.; VALENTINI, R. Neural network based prediction of roughing and finishing times in a hot strip mill. Revista De Metalurgia, [S. l.], v. 46, n.

1, p. 65-75, 2010. DOI: 10.3989/revmetalm.0850. Disponível em: <https://doi.org/10.3989/revmetalm.0850>. Acesso em: 16 ago. 2024.

OLIVEIRA, Danilo G. de; SILVA, Eliton M. da; PARPINELLI, R. S.; et al. Artificial neural network model for steel strip tandem cold mill power prediction. In: INTERNATIONAL CONFERENCE ON INDUSTRIAL, ENGINEERING AND OTHER APPLICATIONS OF APPLIED INTELLIGENT SYSTEMS, 33., 2020, Kitakyushu. Proceedings... [S. l.]: Springer, 2020. p. 31-41. DOI: 10.1007/978-3-030-61702-8_3. Disponível em: https://doi.org/10.1007/978-3-030-61702-8_3. Acesso em: 16 ago. 2024

JONES, D. M.; WATTON, J.; BROWN, K. J. Comparison of hot rolled steel mechanical property prediction models using linear multiple regression, non-linear multiple regression and non-linear artificial neural networks. Ironmaking & Steelmaking, [S. l.], v. 32, n. 5, p. 424-431, 2005. DOI: 10.1179/174328105X48151. Disponível em: <https://doi.org/10.1179/174328105X48151>. Acesso em: 16 ago. 2024.

CHIEN, Li-Jen; THOMAS, C. L.; LAWSON, Del R. Sensor/model fusion for improved process understanding and control in injection molding. In: ASME INTERNATIONAL MECHANICAL ENGINEERING CONGRESS AND EXPOSITION, 1997, Dallas. Proceedings... [S. l.]: ASME, 1997. p. 123-130. DOI: 10.1115/IMECE1997-0629. Disponível em: <https://doi.org/10.1115/IMECE1997-0629>. Acesso em: 16 ago. 2024.

STEWART, C.; AMINOSSADATI, S.; KIZIL, M. Predictive network modelling with live sensor data. In: INTERNATIONAL CONFERENCE FOR FIBRE-OPTIC AND PHOTONIC SENSORS FOR INDUSTRIAL AND SAFETY APPLICATIONS, 2., 2017, Brisbane. Proceedings... [S. l.]: IEEE, 2017. p. 45-50. DOI: 10.1109/OFSIS.2017.16. Disponível em: <https://doi.org/10.1109/OFSIS.2017.16>. Acesso em: 16 ago. 2024.