

INTELIGÊNCIA ARTIFICIAL APLICADA À PREDIÇÃO DO KAPPA NO PROCESSO DE COZIMENTO KRAFT

Carlos Eduardo Almeida Luz¹, Rodrigo Augusto Barella¹, Aline Scheid Martins², Juliana Giancoli Martins de Sousa³, Paulo Jose de Castro⁴, Alessandro Pini⁵, Thaís Simões de Almeida Ribeiro¹

¹ Suzano S.A. – Tribo Digital Industrial – Squad Produção de celulose

² Suzano S.A. – Unidade Três Lagoas/Brasil – Squad Produção de celulose

³ Suzano S.A. – Unidade Jacarei/Brasil - Squad Produção de celulose

⁴ Suzano S.A. – Unidade Imperatriz/Brasil – Linha de fibras

⁵ Suzano S.A. – Unidade Três Lagoas/Brasil – Linha de fibras

RESUMO

No processo de produção de celulose Kraft, temos o cozimento como primeira etapa crítica para transformação dos cavacos de madeira em polpa celulósica. Garantir a extração da fibra de celulose de forma eficiente, com a retirada adequada de lignina, são uns dos principais desafios desse processo. O número Kappa é um número adimensional, que nos indica indiretamente a quantidade residual de lignina durante o cozimento como apontado por Correia *et al.* (2019). Acompanhar o kappa entregue pelo digestor é crítico, pois, por meio da sua estabilização, garantimos uma polpa uniforme, além do seu ótimo valor poder maximizar a entrega de rendimento na polpação, garantindo um consumo de químicos adequado no branqueamento.

Antecipar o valor do Kappa nos garante correções preventivas ao longo do cozimento, possibilitando além de mais estabilidade e rendimento, aprimorar as leituras dos sensores e analisadores físicos. Avanços recentes na ciência de dados e na capacidade de coletar e analisar dados de sensores para aplicação em modelos de Inteligência Artificial, nos permitiram desenvolver uma predição do número kappa tanto para digestores Low Solids como Compact Cooking G2, com até 3 horas de antecedência.

Este trabalho tem como objetivo apresentar os avanços alcançados pela Suzano na implementação de modelos de rede neural capazes de prever o valor do kappa na descarga do digestor, como uma ferramenta promissora para otimizar o processo de polpação Kraft.

Palavras-chave: rede neural, número kappa, digestor, preditor

INTRODUÇÃO

No processo de polpação de celulose, o número Kappa é uma metodologia utilizada para medir o total de matéria oxidada pelo permanganato de potássio (KMnO₇), composta principalmente por lignina residual e outras estruturas como ácidos hexenurônicos, extrativos e grupos carbonilas presentes na ce-

lulose (Costa e Colodette, 2007). Controlar o número Kappa em um digestor contínuo é um dos principais objetivos para manter a qualidade da celulose, o que muitas vezes pode ser complexo devido a distúrbios inerentes ao processo e mudanças na qualidade do cavaco utilizado como matéria-prima, além de que a presença de medidores on-line na descarga do digestor não permite a correção antecipada de possíveis problemas (RAHMAN *et al.*, 2019). Dessa forma, controlar efetivamente o kappa leva à redução no custo de produção, aumento no rendimento da fábrica, sem aumentar o consumo de madeira, redução no consumo de produtos químicos e à garantia da excelência no processo produtivo. Além disso, o processo de cozimento no digestor, seja ele Compact Cooking ou Low Solids, demora várias horas e, tendo em vista que o número kappa é medido apenas na descarga do digestor, os impactos dos ajustes realizados levam de 90 a 200 minutos a serem confirmados pelos analisadores. Logo, a adoção de uma metodologia que permita prever antecipadamente o número kappa se mostra interessante, tornando possível realizar ações preventivas de forma a evitar grandes variações no processo de cozimento, reduzindo possíveis impactos nas etapas subsequentes.

Estratégias de controle de Kappa puramente feedback tendem a não desempenhar bem durante momentos transitórios de processo devido à complexidade e ao atraso de tempo entre variáveis medidas e manipuladas. Características da madeira utilizada, controle adequado de temperatura, nível de cavacos e licor no digestor e carga alcalina são algumas das variáveis que podem afetar significativamente o número kappa.

Dessa forma, abordagens utilizando modelagem preditiva têm sido exploradas para ter maior previsibilidade no comportamento do kappa. Correia *et al.* (2017) compararam quatro métodos de inferência dinâmica para a predição do Kappa: *Single Exponential Smoothing* (SES), ARIMA, regressão linear

múltipla e redes neurais artificiais e constataram que o modelo ARIMA apresentou maior acurácia, sendo considerado adequado para utilização como um sensor virtual na antecipação da tendência do Kappa.

Ahvenlampi *et al.* (2004) investigaram a aplicação de uma abordagem híbrida ou caixa cinza na modelagem do Kappa, a partir do modelo cinético de Gustafson e modelos de clusterização fuzzy para a estimativa dos perfis de temperatura e álcali no digestor. Os autores demonstraram um desempenho significativamente superior na detecção de alterações no comportamento do kappa a partir do modelo híbrido quando comparado com uma abordagem puramente caixa preta (redes neurais artificiais).

Phatwong e Koolpiruck (2019) utilizaram dados simulados a partir do modelo cinético simplificado de Gustafson para treinar modelos de redes neurais recorrentes do tipo LSTM na modelagem do Kappa e obtiveram erros de até 2,94% na previsão com um horizonte de 3 horas, o que tornaria o modelo aplicável a uma estratégia de controle feedforward.

Mais recentemente, uma nova metodologia de modelagem, utilizando redes neurais profundas recorrentes baseadas na arquitetura de *transformers*, vem ganhando notoriedade, principalmente devido à sua aplicação no contexto de processamento de linguagem natural, o que no momento se tornou padrão para os *Large Language Models* (LLM). A aplicação dessa arquitetura para problemas envolvendo séries temporais também tem sido investigada devido à sua capacidade de processamento paralelo e oferece uma alternativa eficiente comparada a métodos de deep learning como RNNs, LSTMs e GRUs (AHMED *et al.*, 2023).

No presente estudo, investigamos a aplicação de modelagem baseada na arquitetura de redes neurais profundas utilizando camadas LSTM e *transformers* para a modelagem preditiva do número kappa em um digestor contínuo do tipo Compact Cook G2 (Valmet) a partir de sequências de entrada representando o histórico recente do processo.

MÉTODOS

1. Definição do Digestor e Aquisição dos Dados

Com o objetivo de criar um modelo preditivo do kappa, selecionamos um digestor com tecnologia Compact Cook G2 (Valmet), com produção projetada de 5.550 toneladas de celulose seca ao ar por dia e volume de 4750 m³. Esse digestor historicamente apresentou alta variação no número kappa, sendo um candidato interessante para testar essa nova abordagem.

Os dados utilizados foram coletados de forma automatizada por sensores instalados ao longo do digestor em uma frequência de um em um minuto e submetidos à análise e limpeza para remoção de erros na coleta dos dados, *outliers* e criação de variáveis provenientes das leituras coletadas. Tendo em vista a modelagem proposta nesse trabalho, não foi realizada correção nos tempos de retenção para as variáveis

de processo. Além disso, para que o modelo pudesse aprender a detectar paradas ou retomadas de produção, não foram excluídos períodos com ritmo de produção baixo. O período dos dados consistiu em um intervalo de 12 meses consecutivos em que 85% da amostra foi usada para treinamento do modelo e o restante foi usado para validação. As métricas utilizadas para avaliação e seleção do melhor modelo foram r^2 e erro médio absoluto (MAE). Além disso, os modelos foram comparados com um modelo naïve que considera que o kappa em 180 minutos no futuro será o último valor de kappa medido pelo instrumento.

Foram consideradas como variáveis de entrada do modelo o perfil de temperatura ao longo do digestor, ritmo de produção, carga de álcali e nível de cavacos no digestor além da própria leitura de kappa aferida instrumentalmente via kappa bright. Tendo em vista que as leituras de kappa acontecem em um intervalo de 30 a 40 minutos, para análise dos resultados previstos pelo modelo, foram desconsideradas medidas consecutivas com o mesmo valor de kappa.

2. Definição dos modelos

Tendo em vista a dinâmica do digestor, os modelos foram treinados utilizando uma janela móvel de dados com o objetivo de fazer com que as arquiteturas escolhidas pudessem aprender o comportamento interno do equipamento. As previsões foram realizadas em uma janela de 180 minutos, representando metade do tempo total de residência do digestor em questão, permitindo sua utilização em controle antecipado com o principal objetivo de reduzir o desvio padrão do kappa. O treinamento dos modelos foi realizado usando a ferramenta de computação na nuvem da Google chamada Vertex AI.

Devido à alta disponibilidade de dados, escolhemos algumas abordagens de aprendizado profundo com o objetivo de prever antecipadamente o kappa, dentre elas *Long Short Term Memory* (LSTM) e *Transformers*.

3. Long Short-Term Memory (LSTM)

LSTM são um tipo de modelo de redes neurais recorrentes (RNN) melhorados para abordagens que envolvam atividades como tradução, reconhecimento de voz e previsão de séries temporais, tendo em vista o comportamento sequencial dos dados nesse tipo de atividade. Essa arquitetura foi definida e apresentada por Hochreiter & Schmidhuber (1997). Tendo em vista que uma RNN tradicional possui apenas uma única camada de estado oculto, o aprendizado de dependências a longo prazo se torna difícil nesse tipo de arquitetura. Hochreiter & Schmidhuber propuseram resolver essa questão introduzindo uma célula de memória que nada mais é do que uma camada que consegue reter informações de períodos passados.

4. Transformers

Transformers são modelos apresentados por Vaswani *et al.* (2017). Esse tipo de arquitetura foi proposto inicialmente para

modelos de linguagem natural (NLP), baseando-se na metodologia de tradução textual definida por Bahdanau *et al.* (2014) e apresenta algumas vantagens como maior velocidade no treinamento, quando comparado com LSTMs, e maior capacidade de aprendizado contextual devido às camadas de atenção. Desde seu surgimento, *transformers* tem sido empregados em diferentes áreas como áudio, robótica e séries temporais, além de NLP e visão computacional.

5. Testes do Modelo

Foram realizados testes em planta com o objetivo de verificar a eficácia das previsões no controle antecipado do kappa. Para realização dos testes, foram propostas as seguintes condições:

1. Usando o manual do digestor, calculamos o fator H através da equação 1.
2. Calculamos a distância entre o kappa previsto e o target de kappa definido pela produção da unidade industrial.
3. Calculamos o ajuste necessário no fator H para corrigir a distância calculada no passo 2.
4. Convertemos, usando novamente a equação 1, o fator H resultante do passo 3 para temperatura.
5. Sugerimos alterar o *setpoint* de temperatura para o resul-

tante do passo 4.

RESULTADOS E DISCUSSÃO

Por motivos de confidencialidade, o conjunto de dados contendo os valores observados e previstos de kappa foram normalizados utilizando o mínimo e o máximo das observações. É importante frisar que cada ponto previsto de kappa foi realizado para 180 minutos no futuro. Em outras palavras, um kappa previsto no valor de 0.37 em 15 de fevereiro às 13h34 teve sua previsão sendo realizada no dia 15 de fevereiro às 10h34, assim como mostra a Figura 1.

A Figura 2 apresenta a evolução temporal das previsões realizadas pelo modelo durante o mês de fevereiro dentro do período de validação. É possível notar que o modelo conseguiu aprender e prever com sucesso a tendência do kappa durante o período analisado, bem como adiantar alguns movimentos de subida ou descida do kappa entre os dias 12, 13 e 14, e de 20 a 21 de fevereiro, movimentos estes que foram confirmados pelas leituras instrumentais. No entanto, também é possível notar que em alguns períodos o modelo acabou replicando o comportamento das leituras instrumentais do kappa, como podemos observar nos dias 11, 16 e 17 de fevereiro. Esse com-

$$T = \left(16161.62 \div \left(43.33 - \ln \left(\text{Fator } H \right) \div \left(\text{tempo retencao} \right) \div 60 \right) \right) - 273$$

Equação 1. Cálculo do fator H do digestor




Figura 1. Previsão futura do kappa




Figura 2. Kappa previsto VS Kappa observado durante o mês de fevereiro




Figura 3. Comparação das previsões do modelo VS modelo naive




Figura 4. Série temporal do kappa previsto e do kappa observado durante o mês de junho de 2024

portamento pode ser verificado na Figura 3 ao compararmos as curvas do kappa previsto contra o *naive*. Pode-se notar que nos dias citados anteriormente, o modelo acabou ficando bem parecido com a previsão do modelo naive, mostrando que a variável de relevância para as previsões em questão foi a própria leitura de kappa. Como todas as variáveis usadas para inferência estão sendo medidas no próprio digestor, não se tem visão das características da madeira, como umidade e densidade por exemplo. Dessa forma, nossa hipótese é de que existam variáveis que não foram selecionadas para treinamento que possam explicar os movimentos de descida ou subida não previstos pelo modelo nesses dias.

Considerando um período mais recente, com o modelo realizando novas previsões a cada 10 minutos, podemos verificar sua boa aderência e performance no mês de junho por meio da Figura 4. Importante ressaltar que não temos observado decréscimo na performance do modelo nos últimos meses, sendo essa uma característica interessante da arquitetura desenvolvida para o desafio em questão.

As tabelas 1 e 2 apresentam as métricas de treinamento do modelo proposto e do modelo naive, respectivamente. Podemos notar que novamente o modelo proposto teve um desempenho melhor que o naive, reforçando a relevância da arquitetura desenvolvida. Além disso, quando comparado com outras arquiteturas propostas na literatura como mencionado por

Tabela 1. Métricas de treinamento do modelo

Métrica	Resultado
r^2	0.18
MAE	1.19
MSE	3.54

Tabela 2. Métricas de análise do modelo naive

Métrica	Resultado
r^2	0.06
MAE	1.31
MSE	4.07

Correia *et al.* (2018), o modelo desenvolvido nesse trabalho se destaca pela capacidade de prever e antecipar o kappa em metade do tempo de retenção do digestor.

Em relação aos testes realizados em planta, entre os dias 26 e 28 de junho de 2024, foi possível constatar uma redução de 40% no desvio padrão do kappa, como apontado na Figura 5, na qual comparamos o desvio padrão do kappa nos dias de teste *versus* o mês de maio usado como controle. Tendo em vista que tivemos apenas três pontos para criação da análise com o controle ligado, é natural que a dispersão fique muito grande como apontado no gráfico. Vale destacar que, por motivos de confiabilidade e segurança durante os testes, não foram aplicadas




Figura 5. Análise do desvio padrão do kappa nos dias de teste versus mês anterior

Tabela 3. Média do desvio padrão do kappa nos últimos seis meses comparado aos dias de teste entre 26 e 28 de junho

	Média de dezembro a maio	Testes 26 a 28/06
Desvio padrão kappa	1.24	0.8

a totalidade dos ajustes recomendados pelo modelo. Portanto, é de se esperar que a redução no desvio padrão pode ser ainda maior à medida que pequenos ajustes no modelo e na forma de aplicar as recomendações no controle sejam realizados, além de que um período maior com o controle ligado se faz necessário para que todo o potencial desse modelo seja explorado. Além do avanço técnico significativo, a modelagem apresentada trouxe um avanço importante nas estratégias de controle de kappa em indústrias de celulose.

Por fim, podemos visualizar na Tabela 3 um comparativo da média mensal do kappa entre os meses de dezembro de 2023 a maio de 2024 *versus* a média do desvio nos dias de teste, comprovando a redução decorrente do controle de temperatura baseado na previsão do kappa.

CONCLUSÃO

Como apresentado, o modelo proposto não só foi capaz de prever a tendência do kappa, como também foi capaz de adiantar o kappa, permitindo seu uso em controles antecipados como demonstrado nos testes.

Durante o período testado, houve redução em 40% no desvio padrão do kappa, o que não só é um avanço impactante nas tecnologias e metodologias de controle de kappa, como também representa uma redução significativa nos custos de madeira para a produção de celulose. ■

REFERÊNCIAS

- Ahmed, S., Nielsen, I. E., Tripathi, A., Siddiqui, et al. Transformers in time-series analysis: a tutorial. *Circuits, Systems, and Signal Processing*, v. 42, p. 7.433-7.466. (2023).
- Ahvenlampi, T., Rantanen, R., Tervaskanto, M. e Kortela, U. Enhancing controllability of kappa number using gray-box modeling?. *IFAC. Proceedings Volumes*, v. 37, n. 6, p. 85-90. (2004).
- Bahdanau, Dzmitry & Cho, Kyunghyun & Bengio, Y. (2014). Neural Machine Translation by Jointly Learning to Align and Translate. *ArXiv*. p. 1.409.
- Correia, F. M., d'Angelo, J. V. H., Almeida, G. M., Mingoti, S. A. Predicting Kappa number in a kraft pulp continuous digester: a comparison of forecasting methods. *Brazilian Journal of Chemical Engineering*, v. 35, n. 3, p. 1081-1094. (2018).
- Costa, M. M. e Colodette, J. L. Th e impact of kappa number composition on eucalyptus kraft pulp bleachability. *Brazilian Journal of Chemical Engineering*, v. 24, n. 1, p. 61-71. (2007).
- Hochreiter, Sepp & Schmidhuber, Jürgen. (1997). Long Short-Term Memory. *Neural computation*. v. 9. p. 1.735-1.780. 10.1162/neco. (1997).
- Phatwong, A. e Koolpiruck, D. Kappa number prediction of pulp digesters using LSTM neural network. *In: 16th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology*, p. 151-154 (2019).
- Rahman, M., Avelin, A. e Kyprianidis, K. An approach for feeforward model predictive control of continuous pulp digesters. *MDPI. Processes*, v. 7, n. 9, p. 602-622. (2019).
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L. e Polosukhin, I. *Attention Is All You Need*. arXiv:1706.03762v1 (2017).