



ConBRepro

XIV CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO

I CIGELUBRA

Congresso Internacional de Gestão e Engenharia Luso-Brasileiro

04 a 06 de dezembro de 2024

Energias Limpas nas Engenharias

Aprendizado de máquina para previsão de variáveis sensoriais em processos de escalonamento: uma revisão da literatura

Lucas Gabriel Silvestre da Cruz

Escola Politécnica, Engenharia Mecatrônica - PUC/PR

Gilberto Reynoso-Meza

Programa de Pós-Graduação em Engenharia de Produção e Sistemas – PUC/PR

Fernando Roberto Mayer

Programa de Pós-Graduação em Engenharia de Produção e Sistemas – PUC/PR

Cesar Costa

Escola Politécnica

Resumo: A indústria alimentícia enfrenta desafios significativos no escalonamento de processos produtivos, especialmente envolvendo a manutenção de atributos sensoriais como sabor, textura e aparência. Embora as técnicas tradicionais de escalonamento sejam amplamente utilizadas, sua aplicação em cenários complexos é demandante de tempo e exige um amplo conhecimento dos processos envolvidos. Este artigo aborda a implementação de machine learning para prever e otimizar variáveis sensoriais durante o escalonamento na produção de alimentos. A pesquisa visa explorar como essas técnicas podem melhorar a precisão e eficiência dos processos de escalonamento, reduzindo a dependência de modelos matemáticos tradicionais. Para isso, foi realizada uma revisão de literatura utilizando palavras-chave como "machine learning", "scale-up", e "percepção sensorial", resultando na seleção de 10 artigos relevantes. Os resultados mostram que o uso de redes neurais artificiais (ANN) e outros modelos de machine learning apresentam ganhos significativos na previsão de variáveis sensoriais, superando abordagens tradicionais. O estudo destaca a eficiência da aplicação dessas tecnologias na indústria alimentícia e sugere o uso de modelos híbridos para futuros trabalhos.

Palavras-chave: ampliação de escala, aprendizado de máquinas, percepção sensorial.

Machine learning for predicting sensory variables in scale-up processes: a literature review

Abstract: The food industry faces significant challenges in scaling up production processes, particularly involving the maintenance of sensory attributes such as taste, texture, and appearance. Although traditional scaling techniques are widely used, their application in complex scenarios is time-consuming and requires extensive knowledge of the processes involved. This article discusses the implementation of machine learning to predict and optimize sensory variables during scale-up in food production. The research aims to explore how these techniques can improve the accuracy and efficiency of scaling processes, reducing reliance on traditional mathematical models. To achieve this, a literature review was conducted using keywords such as "machine learning," "scale-up," and "sensory perception," resulting in the selection of 10 relevant articles. The results show that the use of artificial neural networks (ANN) and other machine learning models provides significant gains in

predicting sensory variables, surpassing traditional approaches. The study highlights the efficiency of applying these technologies in the food industry and suggests the use of hybrid models for future works.

Keywords: scale-up, machine learning, sensory perception.

1. Introdução

A indústria de alimentos depende fortemente da percepção sensorial para avaliar a qualidade do produto e aceitação do consumidor, que é sensível a atributos como sabor, textura e aparência (Bahramparvar et al., 2014b). Diversos métodos são utilizados para quantificar os parâmetros, como painéis ou testes com consumidores, e são utilizados para construir modelos que regem as qualidades finais do produto, com base nas especificações durante o processo.

Entretanto, por mais que os parâmetros estejam sendo controlados e monitorados em escala laboratorial durante o desenvolvimento, após a transição para uma linha de produção em larga escala, os resultados serão diferentes, devido a não-linearidade dos processos de fabricação.

Em resposta a este desafio, foram desenvolvidas técnicas de scale-up, que consistem na ampliação de um processo e de sua capacidade de produção, mantendo ou melhorando a qualidade dos resultados obtidos durante a fase de experimentação. O dimensionamento de cada processo exige uma análise detalhada, identificando os parâmetros mais relevantes e os mantendo o mais próximo possível de um valor constante (Schmidt, 2005).

Monitorar e controlar esses parâmetros com métodos tradicionais é difícil, tipicamente custosos e demandantes em tempo. Para isto, métodos de aprendizagem de máquina, que são capazes de reconhecer padrões complexos e ocultos a partir de grandes quantidades de dados, e transformá-los em previsões que aumentam a precisão, e reduzem a complexidade do modelo (Ji et al., 2023, apud Viejo et al., 2019).

Apesar dos avanços significativos de aplicações de machine learning em diversos setores, a literatura existente sobre o uso dessas técnicas para o escalonamento de processos na indústria alimentícia ainda é limitada. A maioria dos estudos publicados concentram-se na predição da aceitação final de alimentos (Bahramparvar et al., 2014b), otimização de processos biológicos (Schmidt, 2005; Du et al., 2022) ou químicos (Zlokarnik, 2006; Serra et al., 2003; Rathore et al., 2002; Nastaj; Wilczynski, 2021), deixando uma lacuna em como utilizar os modelos para o scale-up, e tratamento de parâmetros sensoriais.

Nesse contexto, o presente estudo busca contribuir para a evolução da indústria alimentícia por meio de uma revisão de literatura, identificando as soluções que abordam o problema de escalonamento com o auxílio de técnicas de aprendizado de máquina. Além disso, o trabalho busca evidenciar as técnicas de machine learning que obtiveram melhores resultados em estudos de áreas semelhantes, para que possam ser replicados em um problema de otimização multiobjetivo de parâmetros sensoriais, para escalonamento na indústria alimentícia.

A seleção dos artigos foi realizada por meio de palavras-chave que afunilam o resultado, e foram filtrados por relevância e número de citações. Os artigos escolhidos devem abordar ao menos um dos tópicos, entre machine learning e scale-up, e podem ser de áreas externas à indústria alimentícia, devido à lacuna na literatura.

Este trabalho foi organizado da seguinte maneira: na seção 2 a metodologia utilizada para a revisão de literatura; na seção 3 é apresentada a revisão de literatura, abordando os estudos analisados; na seção 4 são analisados os resultados encontrados, e na subseção 4.1 a discussão dos resultados obtidos com os encontrados na literatura; e finalmente, na seção 5, as conclusões obtidas.

2. Metodologia

Durante a seleção de artigos para a revisão, foram realizadas buscas a partir da combinação de palavras-chave, como “engineering”, “food industry”, “scale-up”, “machine learning”, “optimization”, “pilot plant”, industrial scale”, “chemistry”, “multiobjective” e “sensory perception”.

Para o mecanismo de busca, foram utilizadas as principais combinações das palavras-chave com a utilização dos operadores booleanos AND e OR, e então escolhidos com base na relevância. Foram selecionados 16 artigos com base neste critério.

Após a primeira busca, foram selecionados os estudos que incluem modelagem de processos alimentícios ou similares utilizando machine learning, assim como estudos que trazem informações relevantes para processos de scale-up. Mesmo que o artigo não explore diretamente o processo de escalonamento, ainda foram selecionados aqueles que mencionam a possibilidade de aplicação, devido a lacuna na literatura, resultando em 10 referências para a revisão.

3. Referencial Teórico

O processo de escalonamento em plantas industriais é um grande desafio da engenharia, devido à complexidade de se manter os resultados de uma escala laboratorial para industrial, no setor alimentício, esse processo é ainda mais crítico, pois pequenas alterações nas características do processo resultam em diferenças notáveis no produto.

Apesar de apresentem dificuldades e demandem tempo, as técnicas tradicionais de escalonamento são eficazes para ampliar processos, mantendo a similaridade dos resultados, desde que atendam requisitos estudados na literatura.

A publicação de Zlokarnik (2006) aborda o scale-up profundamente, destacando a análise dimensional como uma ferramenta fundamental para o entendimento e para a análise de processos na engenharia, mais especificamente, com exemplos para a área da química. A análise dimensional é essencial para scale-up's pois possibilita a compreensão de fenômenos físicos a partir de modelos matemáticos simplificados, utilizando valores adimensionais como parâmetros. É um método sistemático que permite a identificação de variáveis relevantes para um escalonamento correto, excluindo parâmetros desnecessários e garantindo precisão e a previsão dos parâmetros durante a transição da escala laboratorial para a produção em larga escala.

Cullen (2009) traz em seu livro uma visão geral da indústria de alimentos quanto a processos envolvendo misturadores, reunindo informações como conceitos básicos, tendências, desafios e aplicações específicas. Em um dos capítulos, Dickey (2009) aborda o escalonamento para misturadores, com uso da técnica de análise dimensional para três cenários diferentes, dentre eles, um exemplo com similaridade geométrica, um misturador sem similaridade geométrica, e com ingredientes em pó. Com base nesses conceitos e técnicas, inovações tem surgido para facilitar o escalonamento e a otimização de processos industriais. A aplicação de machine learning torna a modelagem de etapas e fenômenos físicos mais acessível, permitindo novas abordagens de scale-up.

Ji et al. (2023) reúne em uma revisão de literatura os avanços recentes no uso de machine learning para a previsão e regulação de sabor na indústria de alimentos, reunindo publicações e exemplos de aplicações destas técnicas em diferentes cenários. Após avaliar a literatura existente, os autores concluem que a implementação de ML demonstrou uma performance excelente, e tem apresentado uma utilização crescente no setor alimentício. A utilização de modelos híbridos de ML, quando combinado com outras técnicas de aquisição ou tratamento de dados são particularmente importantes para a previsão e manutenção do sabor e qualidade do alimento. A literatura ainda é escassa para aplicações

práticas envolvendo a utilização de machine learning, mas deve continuar chamando atenção e otimizando os métodos relevantes para atender as expectativas do consumidor. Os autores também reforçam que é sempre necessário comparar a precisão entre os diferentes algoritmos, e que o uso simultâneo de diversos métodos de machine learning e diferentes técnicas para aquisição de dados pode demonstrar resultados melhores do que utilizar somente um modelo para a previsão de sabores

Bahramparvar et al. (2014b) abordam uma solução utilizando Artificial Neural Networks (ANN) com uma camada oculta e dez neurônios para prever a aceitação total de sorvetes. Os atributos utilizados foram aparência, sabor, corpo, textura, temperatura, firmeza, viscosidade, suavidade e taxa de liquefação. Os atributos mais impactantes foram sabor e textura. Para a obtenção dos dados de entrada, foi montado um painel com dez membros, que após um treinamento de trinta minutos diários durante um mês, provaram diferentes amostras de sorvete e avaliaram os atributos em uma escala de um a nove. Os autores concluíram que os resultados apresentados afirmam o potencial do modelo de ANN para a prever a aceitação total de sorvetes.

Bahramparvar et al. (2014a) tratam da aplicação do sistema de inferência neuro fuzzy adaptativo (ANFIS) para o desenvolvimento de um modelo capaz de simular e prever a aceitação geral de sorvetes com base nos atributos sensoriais. As informações que compõem conjunto de dados do experimento foram coletadas através de painéis sensoriais, e aplicados no modelo ANFIS, que reúne a capacidade de determinação de parâmetros da ANN com a lógica fuzzy. O algoritmo desenvolvido mostrou ser eficaz para a previsão da aceitação geral do sorvete, entendendo as relações complexas entre os parâmetros sensoriais sem a necessidade de um modelo matemático. Os resultados obtidos indicam que o ANFIS alcançou uma precisão elevada, com um percentual de erro médio de 5,11% e precisão de 94,89%, mostrando ser uma técnica capaz de superar dificuldades na aceitação de alimentos, podendo ser replicado em outros projetos com resultados satisfatórios.

Qadri, Osama e Srivastava (2020) publicaram um estudo que modela o processo de secagem em leito de espuma aplicado ao mamão, utilizando algoritmos de aprendizado de máquina. O trabalho desenvolveu três modelos baseados em redes neurais artificiais (ANN), regressão por vetores de suporte (SVR) e regressão por processo gaussiano (GPR). Embora o artigo não trate diretamente de escalonamento de processos, ele oferece contribuições valiosas para o desenvolvimento de modelos de aprendizado de máquina voltados à simulação de processos alimentícios. Para criar o conjunto de dados do experimento, os autores conduziram a secagem do mamão em diferentes condições, variando a temperatura (40, 45 e 50 °C), a potência (480, 560 e 640 W) e a espessura da espuma (2, 3 e 4 mm). A estratégia adotada foi a de "um fator por vez", resultando em 27 combinações para o estudo da cinética de secagem do mamão. A cada minuto, a massa e a umidade das amostras eram registradas, a partir das quais foram calculadas a taxa de secagem e a proporção de umidade. As variáveis independentes foram a espessura da espuma, a temperatura, a potência e o tempo, enquanto a taxa de secagem foi a variável dependente ou de resposta. No total, 601 pontos de dados foram coletados, dos quais 135 foram usados como amostra de treinamento, utilizando validação cruzada em 10 dobras, com auxílio da ferramenta Matlab. Os autores avaliaram o desempenho dos modelos utilizando indicadores como RMSE (erro quadrático médio da raiz), MSE (erro quadrático médio), MPE (erro percentual médio), R^2 (coeficiente de determinação), $\text{Rad}j^2$ (coeficiente de determinação ajustado) e χ^2 (qui-quadrado). Como conclusão, o modelo SVR apresentou o melhor desempenho em comparação com GPR e ANN, tanto para dados conhecidos quanto desconhecidos, especialmente em casos de não linearidade. A simulação indicou que a taxa de secagem do mamão aumentou com o incremento da potência e a diminuição da espessura da espuma.

Erenturk e Erenturk (2007) abordam a aplicação de algoritmos genéticos (GA) e redes neurais artificiais (ANN) para modelar e otimizar o processo de secagem de cenouras, tendo como objetivo principal determinar as características do processo em diferentes condições, como temperatura, velocidade do ar e espessura das amostras. Os autores comparam quatro modelos matemáticos disponíveis na literatura e aplicam os modelos de machine learning para otimizá-los. O algoritmo de algoritmos genéticos foi aplicado diretamente no ajuste dos parâmetros, e uma rede neural foi aplicada para prever o conteúdo de umidade das amostras ao longo do processo de secagem. Utilizando indicadores de performance, como R , R^2 , χ^2 e MSE, concluem que a implementação de algoritmos de aprendizado de máquinas foi bem sucedida na previsão da cinemática de secagem. Além disso, com o uso de ANN, o modelo atingiu uma previsão melhor do que 0,05% na estimativa de umidade, minimizando os indicadores de erro e removendo a dependência do modelo matemático.

A partir deste ponto, serão incluídos artigos que aplicam técnicas de scale-up e machine learning em outras áreas, como química e biotecnologia.

Schmidt (2005) tem como objetivo em seu artigo aumentar o rendimento dos produtos e manter a qualidade por meio da otimização de processos e scale-up no campo da fermentação. Para alcançar isso, os autores utilizam estratégias de caracterização do processo, identificam parâmetros-chave e estabelecem parâmetros de escalonamento para garantir a consistência do produto. Além disso, é realizada uma combinação de variáveis físicas e outros parâmetros relevantes para criar grupos matemáticos ou termos adimensionais, fundamentais para a otimização do processo. O autor tem preferência a coleta de dados em tempo real, através de medições in situ (no local) e on-line, com apoio de ferramentas como análise de redes neurais e dinâmica de fluídos computacional. Schmidt aponta que, apesar da literatura abundante e do papel central do escalonamento na biotecnologia, parece não haver uma estratégia comum para todos os cenários. Para cada produto ou processo, uma estratégia adequada e específica precisa ser elaborada. A estratégia sugerida para todos os casos de escalonamento é a caracterização abrangente e detalhada do processo para identificar os principais fatores e parâmetros que mais influenciam no rendimento e na qualidade do produto, além de um controle e design apropriado que garantam as condições de mistura e reação ideais, com apoiados por modelos de aprendizado de máquina. Diante da alta complexidade dos parâmetros de fermentação e das diferentes configurações de recipientes e instalações, Schmidt conclui que o sucesso do escalonamento, na maioria dos casos, não será o resultado de uma estratégia conclusiva e linear, mas sim de uma otimização independente em cada escala, dependendo da experiência e da intuição do experimentador.

Du et al. (2022) buscam compreender e modelar os processos de fermentação, buscando uma aproximação para aplicar em modelos de aprendizado de máquinas, beneficiando o design, controle e otimização do processo, minimizando experimentos desnecessários. Os autores fornecem uma visão de diferentes métodos de modelagem matemática e suas aplicações em processo de fermentação biológica, e indicam a utilização de modelos mecanicistas, que envolvem teorias e equações conhecidas do processo, Abordagens orientadas por dados, que são técnicas de machine learning voltadas a utilização de dados conhecidos, e a junção dos dois modelos anteriores, conhecida como modelagem híbrida. Além das abordagens mencionadas, os autores indicam a utilização de modelos computacionais de dinâmica de fluídos para auxiliar na modelagem de processos a serem escalonados.

Alavijeh, Lee e Gras (2024) abordam em seu artigo o tema de scale-up e scale-down em biorreatores para a indústria biofarmacêutica, utilizando técnicas de machine learning para prever parâmetros escalonáveis. Ao longo do estudo, os autores conduziram três experimentos com o objetivo de avaliar a relação entre o crescimento celular e as características escalonáveis dos biorreatores. Em seguida, aplicaram um modelo de

artificial neural network (ANN) para otimizar o processo e identificar similaridades nos diferentes procedimentos. Para os autores, uma vantagem chave desta abordagem (Machine Learning) é a construção de relações matemáticas entre parâmetros escalonáveis e Key Performance Indicators (KPI) sem a necessidade de inclusão de mecanismos subjacentes, dos quais muitos não são bem compreendidos. O primeiro passo foi, por meio de uma revisão de literatura e refinamento do espaço de parâmetros, identificar as variáveis chave que influenciam o processo de escalonamento do biorreator. Essas variáveis foram avaliadas com base em sua relevância técnica, aplicabilidade prática e disponibilidade em experimentos ou cálculos. Além disso, foi considerada a importância física dessas variáveis para uma aplicação industrial real. Em seguida, foi realizado o procedimento de coleta de dados por meio de um estudo detalhado da literatura publicada. Os autores reuniram um total de 18 processos distintos, com 755 séries temporais de medições de 55 biorreatores de diferentes escalas, variando de 250 mL a 5000 L, resultando na formação de um conjunto de dados robusto. Neste estudo, os autores utilizaram o modelo de Artificial Neural Networks (ANN) para auxiliar a construir relações matemáticas entre as variáveis escalonáveis. Em conclusão, o estudo demonstrou o potencial das técnicas de machine learning para a previsão de parâmetros escalonáveis em biorreatores, como o crescimento celular. Destacaram também as limitações que encontraram durante o processo, relacionadas à variabilidade dos dados e fatores geométricos dos biorreatores, que afetaram a capacidade do modelo. Recomendam que futuros conjuntos de dados incluam maior variabilidade de características dos processos e equipamentos, para aumentar a precisão e aplicabilidade dos modelos de machine learning para o escalonamento industrial.

4. Resultados

A metodologia descrita permitiu a seleção de dez artigos relevantes, com contribuições significativas para o campo de estudo e potencial para guiar trabalhos futuros.

Tabela 1 - Comparativo dos artigos coletados

Artigo	Foco do Estudo	Features	Algoritmo de machine learning	Conclusões
Alavijeh, Lee e Gras (2024)	Aumento de escala em biorreatores utilizando aprendizado de máquina	Volume, diâmetro do vaso, proporção, diâmetro do impulsor, entrada de energia por volume, velocidade da ponta do impulsor, número de Reynolds, comprimento de Kolmogorov, tempo de mistura, taxa de agitação, ...	ANN e XGBoost	Eficaz na previsão
Bahramparvar et al. (2014a)	Prever a aceitabilidade do sorvete com base em atributos sensoriais	Aparência, sabor, corpo, textura, frieza, firmeza, viscosidade, suavidade, taxa de liquefação e aceitação total	ANFIS	Alcançou 5,11% de erro médio de predição, coeficiente de correlação de 0,93

Bahramparvar et al. (2014b)	Prever a aceitabilidade do sorvete com base em atributos sensoriais	Aparência, sabor, corpo, textura, frieza, firmeza, viscosidade, suavidade, taxa de liquefação e aceitação total	ANN	Eficaz na previsão, erro médio absoluto de 0,27, coeficiente de correlação de 0,96, o melhor modelo usa uma camada oculta com 10 neurônios
Cullen (2009)	Processos de mistura na indústria de alimentos e escalonamento de misturadores	Número de Reynolds, Froude e Power, diâmetro do tanque, volume, viscosidade e densidade do fluído, velocidade do misturador, tipo e número de lâminas do impulsor, ângulo da lâmina, potência, torque, velocidade da ponta, ...		Métodos e exemplos de escalonamento de misturadores sem implementar técnicas de machine learning
Du et al. (2022)	Otimização e escalonamento dos processos de fermentação	Temperatura, pH, aeração, concentração de substrato, ...	ANN, SVM, PCA, modelagem cinética e baseada em restrições (CBM)	O autor destaca a relevância de modelos híbridos de ML com CBM
Erenturk e Erenturk (2007)	Otimização de modelos matemáticos da cinética de secagem da cenoura	Temperatura do ar de secagem, velocidade do ar, espessura	ANN, AG, retropropagação	O modelo de rede neural superou outros modelos em precisão, obtendo um resultado melhor que 0,05% na previsão de umidade da amostra
Ji et al. (2023)	Revisão de literatura para aplicações de aprendizado de máquina na indústria alimentícia	Atributos sensoriais, descritores moleculares, classificação e intensidade de sabores	SVM, DT, RF, kNN, ELM, ANN, DL, GBT, ...	Métodos de aprendizado profundo, floresta aleatória, SVM e fusão de dados são modelos e técnicas frequentemente usados, que

				apresentam resultados promissores
Qadri, Osama e Srivastava (2020)	Modelagem da taxa de secagem com espuma assistida por micro-ondas usando técnicas de aprendizado de máquina	Potência do micro-ondas, temperatura do ar de entrada, espessura da espuma, tempo de secagem, taxa de secagem	ANN, SVR, GPR	O modelo SVT superou o ANN e o GPR
Schmidt (2005)	Otimização e escalonamento de processos de fermentação	Entrada de energia, entrada de energia volumétrica, coeficiente de transferência de oxigênio, velocidade do agitador, tensão de mistura, cisalhamento, taxa de aeração, tempo de mistura, ...	ANN	Para cada produto ou processo, uma estratégia adequada e específica precisa ser elaborada
Zlokarnik (2006)	Escalonamento na engenharia química	Vazão, densidade e viscosidade do fluido, diâmetro, condutividade térmica, temperatura, ...		Apresenta o método de análise dimensional para escalonamentos

Fonte: Dados de pesquisa

Para o escalonamento, a técnica tradicional mais comum é a análise dimensional, conforme discutido por Zlokarnik (2006), amplamente utilizada dentre os estudos revisados. Este tipo de técnica depende de conhecimentos aprofundados sobre os princípios e fenômenos físicos do processo, tornando sua implementação complexa.

A implementação de algoritmos de ML tem sido uma alternativa para modelagem e otimização de parâmetros, com aplicações em diversas áreas, e com ampla variedade de algoritmos.

O modelo de ANN mostrou ser uma ferramenta promissora e amplamente utilizada na previsão e otimização de processos, tanto químicos quanto alimentícios, e a implementação de múltiplas ferramentas tem sido indicada.

Além disso, outros aspectos metodológicos, como o método de coleta e as características do conjunto de dados, também exercem influência significativa no desempenho final do modelo.

4.1 Discussões

A revisão da literatura destaca uma lacuna nas aplicações de aprendizado de máquina para escalonamento, especialmente em relação à percepção sensorial, com poucos estudos oferecendo informações detalhadas e relevantes.

A aplicação de técnicas de ML em processos alimentícios e biotecnológicos tem mostrado resultados promissores, com ganhos significativos em precisão quando comparado a técnicas tradicionais, chegando até mesmo a eliminar a dependência de modelos matemáticos, reduzindo a complexidade deste tipo de operação e tornando-se uma tendência crescente. (ERENTUK, 2007).

A literatura atual menciona a possibilidade da aplicação dos modelos aperfeiçoados por ML para a implementação em escalonamentos, mas é evidente a carência de estudos que abordam esta aplicação diretamente.

5. Conclusões

Este artigo abordou a aplicação de técnicas de machine learning para o escalonamento de processos alimentícios, com ênfase na utilização de variáveis sensoriais, visando contribuir para a evolução da indústria identificando as soluções existentes que abordam este contexto, além disso, busca evidenciar as aplicações que obtiveram melhores resultados, para que possam ser replicadas em projetos futuros, contribuindo para o avanço do ramo.

Após a primeira busca na literatura com base na combinação de palavras-chave, 16 artigos foram selecionados para leitura, e após a exclusão de trabalhos que se distanciam do tema de pesquisa, 10 foram selecionados para a revisão.

O estudo evidenciou a lacuna nas aplicações de escalonamento com ML, se intensificando ainda mais para parâmetros sensoriais. Entretanto, as publicações revisadas apresentaram resultados promissores, obtendo modelos com ganhos significativos de precisão, superando os modelos tradicionais e apresentando soluções que eliminam a dependência de modelos matemáticos.

Este artigo contribui para o avanço da indústria, validando a eficiência da implementação de machine learning para escalonamentos, reduzindo a complexidade dessas operações e aperfeiçoando os resultados obtidos.

No entanto, a pesquisa apresentou limitações, como carência de estudos que abordam esta aplicação diretamente, assim como a dependência dos dados experimentais, que variam os resultados com base na quantidade e de como foram obtidos.

Para estudos futuros, recomenda-se melhorias no dataset, como a utilização de diferentes métodos de aquisição e técnicas de processamento de dados. Para a técnica de ML, a mais promissora tem sido ANN, mas os resultados podem ser melhorados com a implementação de modelos híbridos.

Referências

ALAVIJEH, Masih Karimi; LEE, Yih Yean; GRAS, Sally L. A perspective-driven and technical evaluation of machine learning in bioreactor scale-up: A case-study for potential model developments. **ENGINEERING IN LIFE SCIENCES**, 2024.

BAHRAMPARVAR, Maryam; SALEHI, Fakhreddin; RAZAVI, Seyed MA. Adaptive neuro-fuzzy inference system (ANFIS) simulation for predicting overall acceptability of ice cream. **Engineering in agriculture, environment and food**, v. 10, n. 2, p. 79-86, 2017.

BAHRAMPARVAR, Maryam; SALEHI, Fakhreddin; RAZAVI, Seyed MA. Predicting total acceptance of ice cream using artificial neural network. **Journal of Food Processing and Preservation**, v. 38, n. 3, p. 1080-1088, 2014.

CULLEN, Patrick J. (Ed.). **Food mixing: Principles and applications**. John Wiley & Sons, 2009.

DICKEY, David S. Mixing scale-up. In: CULLEN, Patrick J. (Ed.). **Food mixing: Principles and applications**. John Wiley & Sons, 2009. p. 90-106.

DU, Yuan-Hang et al. Optimization and scale-up of fermentation processes driven by models. **Bioengineering**, v. 9, n. 9, p. 473, 2022.

ERENTURK, Saliha; ERENTURK, Koksul. Comparison of genetic algorithm and neural network approaches for the drying process of carrot. **Journal of food engineering**, v. 78, n. 3, p. 905-912, 2007.

JI, Huizhuo et al. Recent advances and application of machine learning in food flavor prediction and regulation. **Trends in Food Science & Technology**, v. 138, p. 738-751, 2023.

QADRI, Ovais S.; OSAMA, Khwaja; SRIVASTAVA, Abhaya K. Foam mat drying of papaya using microwaves: Machine learning modeling. **Journal of Food Process Engineering**, v. 43, n. 6, p. e13394, 2020.

SCHMIDT, Frank R. Optimization and scale up of industrial fermentation processes. **Applied microbiology and biotechnology**, v. 68, p. 425-435, 2005.

ZLOKARNIK, Marko. **Scale-up in chemical engineering**. John Wiley & Sons, 2006.