

Modelos de Aprendizado Adaptativo para Resposta a Eventos Climáticos Severos: Proposta de Estrutura Metodológica Aplicada à Agroindústria

Adaptive Learning Models for Responding to Severe Weather Events: Proposal of Methodological Framework Applied to Agroindustry

Luiz Fernando Satolo¹, Catarina Barbosa Careta²

¹INPE, ²ESALQ/USP

satololuiz@gmail.com, caretta@usp.br

**Grupo de Trabalho (GT): GT12. Impactos socioambientais das novas tecnologias no
agronegócio**

Resumo

Este trabalho apresenta uma proposta de estrutura metodológica para aplicação de modelos de aprendizado adaptativo para aumentar a resiliência e eficiência de processos industriais agrícolas frente a eventos climáticos extremos. A abordagem integra dados de sensores, informações meteorológicas e parâmetros operacionais, utilizando aprendizado por reforço, redes neurais online e técnicas de otimização estocástica. O objetivo é desenvolver um sistema inteligente de tomada de decisão em tempo real, com capacidade de ajustar automaticamente variáveis de controle como temperatura, umidade e tempo de operação. A metodologia contempla etapas de coleta e fusão de dados, modelagem de processos industriais sensíveis ao clima, e simulação de cenários extremos com validação computacional e experimental. Espera-se oferecer soluções aplicáveis a plantas agroindustriais de médio e grande porte, com ganhos em sustentabilidade, robustez e desempenho operacional.

Palavras-chave: Aprendizado de Máquina, Manufatura Agrícola, Eventos Climáticos Extremos, Indústria 4.0

Abstract

This work proposes a methodological framework for applying adaptive learning models to enhance resilience and efficiency in agricultural industrial processes under extreme weather conditions. The approach integrates sensor data, meteorological information, and operational parameters using reinforcement learning, online neural networks, and stochastic optimization techniques. The aim is to develop an intelligent real-time decision-making system capable of automatically adjusting control variables such as temperature, humidity, and operation time. The methodology includes data fusion, climate-sensitive process modeling, and simulation of extreme scenarios with computational and experimental validation. The expected outcome is a practical solution for medium and large agro-industrial plants, improving sustainability, robustness, and operational performance.

Key words: Machine Learning, Agricultural Manufacturing, Extreme Weather Events, Industry 4.0

1. Introdução

Nas últimas décadas, a intensificação de eventos climáticos extremos tem gerado impactos diretos sobre os sistemas agroindustriais, especialmente em processos sensíveis como secagem, beneficiamento, armazenamento e embalagem. Alterações abruptas em variáveis como temperatura e umidade comprometem o desempenho operacional, reduzem a eficiência energética e afetam a qualidade final dos produtos agrícolas (VIOLA; MENDES, 2022). Diante desse cenário, torna-se essencial o desenvolvimento de sistemas inteligentes de controle e decisão que respondam de forma autônoma a tais variações, aumentando a resiliência da manufatura agrícola frente às incertezas ambientais.

A integração entre ciência de dados e engenharia de produção tem impulsionado soluções inovadoras nesse campo, destacando-se a aplicação de algoritmos de aprendizado de máquina em processos industriais complexos. A literatura recente tem avançado na combinação de modelos matemáticos e técnicas de inteligência artificial voltadas à previsão, otimização e adaptação em ambientes incertos. Zheng et al. (2025) demonstram que a incorporação de redes neurais profundas a modelos fenológicos resulta em previsões mais robustas da produtividade de cultivos sob estresse climático, quando comparadas a

abordagens exclusivamente estatísticas ou mecanicistas. Esses resultados apontam para a importância da modelagem híbrida e adaptativa na gestão da variabilidade climática.

No campo da tomada de decisão em tempo real, o aprendizado por reforço tem se destacado como uma abordagem promissora. Feng et al. (2025) aplicaram algoritmos de reforço profundo (deep reinforcement learning) para otimizar estratégias de resposta a inundações em regiões costeiras vulneráveis às mudanças climáticas, demonstrando ganhos em resiliência e adaptabilidade. Esses avanços reforçam a aplicabilidade da inteligência artificial em cenários onde os parâmetros do ambiente variam dinamicamente e exigem respostas rápidas e eficientes.

Assim, a proposta deste projeto se ancora na convergência entre Agricultura, Inteligência Computacional e Ciências Climáticas, propondo uma abordagem adaptativa orientada por dados. A pesquisa se insere nas diretrizes da Indústria 4.0, especialmente na busca por sistemas agroindustriais autônomos, resilientes e inteligentes. Ao integrar variáveis meteorológicas em tempo real com algoritmos de otimização e controle, pretende-se aumentar a capacidade de resposta das plantas industriais diante de eventos climáticos extremos, promovendo sustentabilidade, eficiência energética e qualidade operacional.

O objetivo geral do trabalho é apresentar uma proposta de estrutura metodológica para aplicação de modelos de aprendizado adaptativo que possibilitem respostas eficientes a eventos climáticos severos na agroindústria.

2. Revisão da literatura

Modelos de aprendizado adaptativo ganharam destaque na literatura como soluções promissoras para problemas em ambientes dinâmicos, incertos e sensíveis ao contexto, como é o caso dos sistemas de manufatura afetados por condições climáticas extremas. Diferente de modelos estáticos, esses algoritmos são capazes de ajustar seus parâmetros ao longo do tempo com base em novas observações, mantendo ou até melhorando o desempenho à medida que o ambiente se transforma.

Dentre as abordagens mais relevantes, destaca-se o aprendizado por reforço (Reinforcement Learning – RL), no qual agentes aprendem políticas de ação otimizadas por meio de interações com o ambiente. Segundo Sutton e Barto (2018), essa classe de algoritmos é particularmente eficaz em situações onde não há um modelo explícito do sistema, e onde a maximização de recompensas acumuladas está sujeita a múltiplas variáveis de contexto. Em aplicações industriais, o RL tem sido utilizado para otimização de processos, controle adaptativo e manutenção preditiva.

Além do RL, outra vertente relevante envolve redes neurais online, capazes de atualizar seus pesos em tempo real por meio de algoritmos de aprendizado contínuo, como o gradiente estocástico com regularização adaptativa (Goodfellow; Bengio; Courville, 2016). Tais redes permitem que modelos se ajustem com eficiência a fluxos de dados não estacionários, sendo ideais para processos industriais sujeitos a mudanças ambientais ou operacionais. Técnicas como dropout dinâmico, reamostragem temporal e esquemas de *experience replay* têm sido propostas para mitigar problemas de sobreajuste e esquecer catastrófico (*catastrophic forgetting*).

Outra frente emergente é o uso de aprendizado não supervisionado adaptativo, especialmente voltado à detecção de anomalias e padrões emergentes em séries temporais multivariadas. Algoritmos como *k-means* incremental, clustering hierárquico com janelas móveis e autoencoders dinâmicos têm sido empregados para reconhecer variações sazonais, eventos extremos e desvios de comportamento que indicam a necessidade de reconfiguração do processo produtivo (Hyndman; Athanasopoulos, 2021).

Na área de agroindústria, essas abordagens ainda são incipientes, mas estudos recentes têm demonstrado seu potencial. Feng et al. (2025) aplicaram métodos de reforço profundo em modelos de adaptação climática com resultados promissores na agricultura e na gestão de recursos hídricos. Viola e Mendes (2022) destacam que, em contextos rurais brasileiros, a aplicação de tecnologias da Indústria 4.0 exige soluções flexíveis e acessíveis, o que reforça o valor estratégico de modelos adaptativos baseados em dados.

3. Metodologia

A metodologia adotada neste trabalho fundamenta-se em uma revisão analítica da literatura científica recente sobre aprendizado adaptativo aplicado a processos agroindustriais e sistemas sensíveis a variações climáticas. Essa revisão orientou a seleção das técnicas mais promissoras, como aprendizado por reforço, redes neurais online e algoritmos de otimização estocástica, assim como as práticas recomendadas para integração de dados multivariados e modelagem de processos sob incerteza. Foram consideradas publicações indexadas em bases como Scopus, IEEE Xplore, Web of Science e Google Scholar, com ênfase em estudos aplicados à engenharia de produção, ciência de dados e agroindústria. A partir desse levantamento, foram delineadas as etapas metodológicas do projeto, desde a coleta e tratamento dos dados até o desenvolvimento e validação dos modelos adaptativos, garantindo coerência científica e aderência às abordagens mais atuais e eficazes.

4. Resultados

A estrutura metodológica proposta é composta por cinco etapas. A primeira etapa compreende a coleta e integração de dados a partir de fontes diversas, como sensores industriais (que fornecem informações sobre temperatura, umidade, tempo de operação e consumo energético), dados climáticos em tempo real provenientes de APIs públicas (INMET, CPTEC, OpenWeather) e sistemas de gestão da produção (ERP, MES) de plantas agroindustriais parceiras. Esses dados serão tratados e integrados em uma base unificada, utilizando técnicas de fusão de séries temporais, normalização, interpolação, engenharia de atributos e redução de dimensionalidade por meio de PCA (*Principal Component Analysis*) e NMF (*Non-negative Matrix Factorization*), conforme proposto por Gillis (2020) e Hyndman e Athanasopoulos (2021).

A segunda etapa refere-se à modelagem computacional dos processos industriais sensíveis ao clima, como secagem, resfriamento e embalagem. Essa modelagem envolve o mapeamento das variáveis de entrada (como condições meteorológicas e parâmetros de controle) e de saída (eficiência, qualidade e consumo), com a construção de modelos matemáticos que incorporam componentes dinâmicos e estocásticos. A simulação do comportamento dos processos sob diferentes condições climáticas deve ser conduzida com base nas metodologias de simulação híbrida e análise de sensibilidade descritas por Law (2024) e Legaard et al. (2023).

A terceira etapa abrange o desenvolvimento dos modelos de aprendizado adaptativo propriamente ditos, utilizando algoritmos de aprendizado por reforço, como Q-learning e Deep Q-Networks (DQN), com funções de recompensa customizadas para refletir metas operacionais de eficiência, sustentabilidade e robustez. Além disso, são implementadas redes neurais com capacidade de atualização online contínua, baseadas em algoritmos de gradiente estocástico com regularização adaptativa, que permitem o ajuste em tempo real a novas entradas de dados. São também exploradas técnicas não supervisionadas para a detecção de padrões emergentes e anomalias em dados ambientais e operacionais, utilizando métodos como autoencoders dinâmicos e agrupamento incremental.

A validação dos modelos é conduzida por meio da simulação de diferentes cenários climáticos extremos, utilizando tanto séries históricas quanto dados sintéticos. Entre os cenários considerados estão ondas de calor, períodos de alta umidade e variações abruptas de temperatura. A análise de desempenho dos modelos inclui métricas como eficiência produtiva, robustez da resposta adaptativa, consumo energético, tempo de adaptação (latência) e capacidade de generalização a eventos não vistos. Técnicas de simulação Monte Carlo e algoritmos de otimização multiobjetivo são utilizados para avaliar trade-offs entre os indicadores de desempenho, conforme a abordagem de Deb (2011) e Parikh e Boyd (2013).

Por fim, a implementação computacional do projeto é realizada com o uso de ferramentas amplamente utilizadas nas áreas de ciência de dados e engenharia, utilizando pacotes de programação em Python (como NumPy, Pandas, Scikit-learn, Keras e PyTorch), plataformas de visualização de dados (Dash, Matplotlib, Seaborn, Grafana), ferramentas de otimização (Gurobi, CPLEX, CVXPY), ambientes de simulação (SimPy, AnyLogic) e sistemas de armazenamento (PostgreSQL, MongoDB e arquivos CSV estruturados).

5. Considerações finais

A proposta busca responder a um desafio real das cadeias agroindustriais diante das mudanças climáticas, aproximando ciência, tecnologia e setor produtivo. Ao integrar dados ambientais e industriais em modelos computacionais adaptativos, contribui para a transformação digital e sustentável do meio rural. A abordagem proposta é replicável em diferentes contextos produtivos e oferece perspectivas para futuras colaborações acadêmicas e transferência de tecnologia. Para trabalhos futuros, espera-se obter um protótipo funcional de sistema inteligente para processos agroindustriais, capaz de ajustar variáveis de controle de forma automática.

Referências

- DEB, K. Multi-objective Optimisation Using Evolutionary Algorithms: An Introduction. In: WANG, L., NG, A., DEB, K. (eds) Multi-objective Evolutionary Optimisation for Product Design and Manufacturing. London: Springer, 2011.
- FENG, K.; LIN, N.; KOPP, R. E.; XIAN, S.; OPPENHEIMER, M. Reinforcement learning-based adaptive strategies for climate change adaptation: An application for coastal flood risk management, Proc. Natl. Acad. Sci. U.S.A. 122 (12) e2402826122, 2025.
- GILLIS, N. *Nonnegative Matrix Factorization*. Philadelphia: SIAM, 2020.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. Cambridge: MIT Press, 2016.
- HYNDMAN, R. J.; ATHANASOPOULOS, G. *Forecasting: Principles and Practice*. 3. ed. Melbourne: OTexts, 2021.
- LAW, A. M. *Simulation Modeling and Analysis*. 6. ed. New York: McGraw-Hill, 2024.
- LEGAARD, C.; SCHRANS, T.; SCHWEIGER, G.; DRGONA, J.; FALAY, B.; GOMES, C.; IOSIFIDIS, A.; ABKAR, M.; LARSEN, P. Constructing Neural Network Based Models for Simulating Dynamical Systems. ACM Comput. Surv. 55, 11, Article 236 (November 2023).
- PARIKH, N.; BOYD, S. *Proximal Algorithms. Foundations and Trends in Optimization*, v. 1, n. 3, p. 127–239, 2013.
- SUTTON, R. S.; BARTO, A. G. *Reinforcement Learning: An Introduction*. 2. ed. Cambridge: MIT Press, 2018.
- VIOLA, E.; MENDES, V. Agricultura 4.0 e mudanças climáticas no Brasil. Ambient. soc., v. 25, 2022.
- ZHENG, J.; YU, L.; DU, Z.; XIAO, L. Improving wheat phenology and yield forecasting with a deep learning-enhanced WOFOST model under extreme weather conditions. *EGUsphere [Preprint]*, 2025.