

INTELIGÊNCIA ARTIFICIAL NA PESQUISA EM IRRIGAÇÃO E DRENAGEM

CÉSAR DE OLIVEIRA FERREIRA SILVA¹

¹ Stormgeo, Avenida Mutinga, 4935, CEP 05110-903, São Paulo, SP, Brasil, cesaroliveira.f.silva@gmail.com.

1 RESUMO

Essa nota científica apresenta a conceituação dos diferentes subcampos da Inteligência Artificial (IA), incluindo Ciência de Dados, Aprendizado de Máquina, Aprendizado Estatístico, Aprendizado Profundo e Aprendizado Generativo, para identificar e descrever as aplicações potenciais de cada um desses subcampos da IA no campo da irrigação e drenagem agrícola. A nota traz conceitos e termos elementares da IA aplicada a problemas reais na pesquisa em irrigação e drenagem, reflexões sobre os elementos das diferentes modelagens e suas aplicações, e perspectivas sobre os usos presentes e futuros destas técnicas.

Keywords: hidrologia, meteorologia, agricultura, ensino, pesquisa

SILVA, C.O.F.

ARTIFICIAL INTELLIGENCE IN IRRIGATION AND DRAINAGE RESEARCH

2 ABSTRACT

This scientific note presents the conceptualization of different subfields of Artificial Intelligence (AI), including Data Science, Machine Learning, Statistical Learning, Deep Learning and Generative Learning, to identify and describe the potential applications of each of these AI subfields in the agricultural irrigation and drainage research. The note includes concepts and basic terms of AI applied to real problems in irrigation and drainage research, reflections on the elements of the different models and their applications, and perspectives on the present and future uses of these techniques.

Keywords: hydrology, meteorology, agriculture, teaching, research

3 INTRODUÇÃO

A variabilidade climática e a escassez de recursos hídricos demandam a implementação de técnicas avançadas de monitoramento e controle, como aquelas possibilitadas pela integração de sensores remotos e tecnologias de modelagem preditiva (Singh, Deshwal, Kumar, 2021), bem como o desenvolvimento de estudos

que envolvam projeções de aumento de demanda e dos impactos das mudanças climáticas na disponibilidade hídrica. Outro desafio é a integração de novas tecnologias de Inteligência Artificial (IA) em sistemas de irrigação e drenagem já existentes, que muitas vezes carecem de flexibilidade para integração de novas tecnologias (Khadra; Lamaddalena, 2024). Há uma necessidade crescente de abordagens interdisciplinares

que combinem conhecimentos de engenharia agrícola, ciências ambientais e ciência de dados para enfrentar esses desafios de maneira holística.

Neste contexto, é crucial conceituar a IA de maneira precisa e subdividi-la em subcampos específicos para apresentar suas aplicações em irrigação e drenagem de forma mais adequada, pois a IA é um campo extremamente amplo que abrange uma vasta gama de técnicas e metodologias. Cada subcampo, como Ciência de Dados, Aprendizado de Máquina, Aprendizado Estatístico, Aprendizado Profundo e Aprendizado Generativo, oferece ferramentas e abordagens distintas que podem ser aplicadas de maneiras específicas para resolver problemas particulares no contexto agrícola. Por exemplo, enquanto a Ciência de Dados pode ser utilizada para integrar e analisar grandes volumes de dados ambientais, o Aprendizado de Máquina pode automatizar e otimizar sistemas de irrigação em tempo real. Já o Aprendizado Profundo pode ser empregado para analisar imagens de satélite e sensores de campo, enquanto o Aprendizado Generativo pode simular cenários complexos para planejar estratégias futuras. Essa subdivisão permite uma aplicação mais direcionada e eficaz da IA, garantindo que as soluções desenvolvidas sejam tanto tecnicamente adequadas quanto economicamente viáveis, atendendo às necessidades específicas do setor agrícola em regiões tropicais como o Brasil.

O objetivo geral desta nota científica é conceituar os diferentes subcampos da IA incluindo Ciência de Dados, Aprendizado de Máquina, Aprendizado Estatístico, Aprendizado Profundo e Aprendizado Generativo, para identificar e descrever as aplicações potenciais de cada um desses subcampos da IA no campo da irrigação e drenagem agrícola.

4 REVISÃO BIBLIOGRÁFICA

4.1 Campos da inteligência artificial

Inteligência Artificial é um termo abrangente que engloba todas as tentativas de criar sistemas que possam realizar tarefas que, quando realizadas por seres humanos, são consideradas inteligentes (Mitchell, 2019). Isso inclui o Aprendizado de Máquina e suas subáreas (como o Aprendizado Profundo e o Aprendizado Generativo) e outras abordagens, como sistemas baseados em regras, lógica, e métodos simbólicos (Nilsson, 2009).

Ciência de Dados é uma disciplina que envolve o uso de técnicas estatísticas, algoritmos de aprendizado de máquina e análise de *Big Data* para extrair informação a partir de dados (Provost; Fawcett, 2013). A ciência de dados combina elementos de estatística, computação e matemática aplicada para analisar grandes volumes de dados e resolver problemas complexos (Schutt; O'neil, 2013; Wickham; Grolemund, 2016).

Aprendizado de Máquina (*Machine Learning*) é uma subárea da inteligência artificial que envolve, prioritariamente, a criação de algoritmos de predição ou tomada de decisão (Murphy, 2012; Hastie; Tibshirani; Friedman, 2009) mediante uso de métodos estatísticos e técnicas de computação para identificar padrões nos dados (Bishop, 2006).

Aprendizado Estatístico é um campo intimamente relacionado ao Aprendizado de Máquina, mas com foco mais acentuado nas técnicas e modelos estatísticos para inferir relações entre variáveis e fazer previsões (Hastie; Tibshirani; Wainwright, 2015).

O Aprendizado de Máquina abrange uma ampla gama de algoritmos que podem ser de difícil interpretação, sendo chamados de modelo “caixa-preta” por não ser possível uma interpretação clara da sua construção. Em contrapartida, o Aprendizado Estatístico tende a enfatizar modelos que são

interpretáveis e baseados em teoria estatística (Cox; Hinkley, 1974).

Aprendizado Profundo (*Deep Learning*) é um subcampo do Aprendizado de Máquina que utiliza redes neurais artificiais com múltiplas camadas (redes neurais profundas) para modelar padrões complexos em grandes volumes de dados (Goodfellow; Bengio; Courville, 2016). Essas redes são particularmente eficazes em tarefas como reconhecimento de imagem, processamento de linguagem natural e jogos (Le Cun, 2015; Schmidhuber, 2015).

Por outro lado, Aprendizado Generativo (*Generative Learning*) é uma área do Aprendizado de Máquina que foca na criação de modelos capazes de gerar novos dados semelhantes aos dados de treinamento (Goodfellow; Bengio; Courville, 2014). Modelos generativos, como as Redes Geradoras Adversariais (GANs) e os Modelos Autoregressivos, podem ser usados para criar imagens, textos, música, entre outros, a partir de padrões aprendidos (Radford, 2015; Kingma; Welling, 2013).

4.2 Aplicações utilizando ciência de dados

As técnicas de ciência de dados permitem a análise de grandes volumes de dados ambientais, climáticos e de solo, que são utilizados como dados de entrada em modelagens das necessidades hídricas das culturas e na otimização de sistemas de irrigação (Sarala, 2020). Por exemplo, estudos recentes utilizaram algoritmos de aprendizado de máquina para prever a evapotranspiração das culturas com base em dados meteorológicos históricos, o que é crucial para determinar a quantidade ideal de água a ser aplicada em diferentes estágios de crescimento (Umutoni; Samadi, 2024).

Outra aplicação relevante é o uso de técnicas de mineração de dados para identificar padrões ocultos em grandes conjuntos de dados de sensores de umidade do solo e estações meteorológicas. Essas

técnicas permitem o desenvolvimento de sistemas de irrigação inteligentes capazes de ajustar automaticamente os volumes de água aplicados, levando em consideração a variabilidade espacial e temporal do solo e das condições climáticas (Rabhi *et al.*, 2021). Além disso, a integração de dados de satélite e drones com modelos de ciência de dados tem sido utilizada para monitorar a eficiência da irrigação e identificar áreas com potencial de melhoria, o que é especialmente relevante para a gestão de grandes propriedades agrícolas (Hemming *et al.*, 2020).

A modelagem preditiva baseada em ciência de dados também tem sido aplicada para a gestão da drenagem em sistemas agrícolas. Estudos recentes mostraram que a combinação de dados de precipitação, umidade do solo e fluxo de água subterrânea com modelos de Aprendizado de Máquina pode prever com precisão os eventos de saturação do solo, permitindo que os sistemas de drenagem sejam acionados de maneira mais eficiente (Oppel, Schumann, 2020; Gimpel *et al.*, 2021; Sayari; Mahdavi-Meymand; Zounemat-Kermani, 2021). Esta abordagem não só melhora a eficiência da drenagem, mas também ajuda a mitigar os efeitos da erosão do solo e o escoamento de nutrientes, problemas críticos em muitas regiões agrícolas.

4.3 Aplicações utilizando aprendizado de máquina e estatístico

O Aprendizado de Máquina tem revolucionado a forma como os sistemas de irrigação automatizados operam. Algoritmos de Aprendizado de Máquina permitem que os sistemas ajustem automaticamente os níveis de irrigação com base em dados em tempo real, como a umidade do solo e previsões meteorológicas (Murphy, 2012; Bishop, 2006). Algoritmos de Aprendizado de Máquina, como redes neurais artificiais e máquinas de vetores de suporte, têm sido aplicados para prever as necessidades de

irrigação de culturas com base em variáveis como umidade do solo, temperatura e precipitação, resultando em sistemas de irrigação mais eficientes e adaptativos (Singh *et al.*, 2024). Essas abordagens permitem a criação de modelos preditivos robustos que podem ajustar as práticas de irrigação em tempo real, reduzindo o desperdício de água e melhorando a produtividade agrícola (Abioye *et al.*, 2022).

A análise de dados de sensores de solo e sistemas de monitoramento ambiental permite a detecção precoce de problemas relacionados à drenagem e à saúde do solo (Jayaraman, Nagarajan, Partheeban, 2022; Singh *et al.*, 2024). A título de exemplo, algoritmos de Aprendizado de Máquina têm sido utilizados para identificar padrões de saturação do solo que precedem a ocorrência de doenças radiculares em culturas tropicais, permitindo a intervenção antecipada e a redução de perdas (Bilali; Taleb; Brouziyne, 2021). Outro exemplo de aplicação é a utilização de Aprendizado de Máquina para otimizar a operação de sistemas de drenagem subsuperficial por meio do ajuste de parâmetros de controle com base em previsões meteorológicas e dados históricos de fluxo de água (Gao *et al.*, 2023).

Dentro do Aprendizado Estatístico, modelos preditivos têm sido desenvolvidos para entender e prever o comportamento de sistemas de drenagem em diferentes condições climáticas (Hastie; Tibshirani; Wainwright, 2015; Yang, Chui, 2021; Abioye *et al.*, 2022). Técnicas estatísticas, como modelos de regressão linear e análise de séries temporais (Cox; Hinkley, 1974), têm sido amplamente utilizadas para prever a demanda hídrica das culturas em diferentes condições climáticas e de solo (Mokhtar *et al.*, 2022). Esses modelos permitem aos agricultores planejar melhor a alocação de recursos hídricos (Silverman, 1986), garantindo que as necessidades das culturas sejam atendidas sem excessos que possam comprometer a eficiência da irrigação.

4.4 Aplicações utilizando aprendizado profundo

Deep Learning tem emergido como uma ferramenta poderosa na pesquisa em irrigação e drenagem, possibilitando avanços significativos na precisão e eficiência desses sistemas (Schmidhuber, 2015; Bengio; Courville; Goodfellow, 2016). Uma das aplicações mais notáveis é o uso de redes neurais convolucionais (CNNs) no monitoramento em tempo real das condições das culturas e da umidade do solo em áreas agrícolas mediante análise de imagens de satélite e drones (Goodfellow; Bengio; Courville, 2016; Le Cun, 2015; Palmitessa *et al.*, 2022).

Essa abordagem permite a identificação precoce de áreas com deficiência hídrica, facilitando intervenções rápidas e direcionadas que otimizam o uso da água (Sayari; Mahdavi-Meymand; Zounemat-Kermani, 2021; Poe, 2023).

Redes neurais recorrentes (RNNs) e suas variantes, como a *Long Short-Term Memory* (LSTM), têm sido aplicadas para prever as necessidades futuras de irrigação com base em séries temporais de dados climáticos e de umidade do solo. Essas redes são particularmente eficazes em modelar padrões complexos de variabilidade climática, que são comuns em regiões tropicais, permitindo ajustes dinâmicos nos sistemas de irrigação a fim de adaptá-los às mudanças ambientais em tempo real (Umutoni; Samadi, 2024).

Outra aplicação promissora do Aprendizado Profundo na irrigação e drenagem é a otimização da operação de sistemas de drenagem subsuperficial por modelos treinados para prever o comportamento do fluxo de água no solo. Esses modelos simulam a interconexão de múltiplos fatores como textura do solo, topografia e condições climáticas (Yang, Chui, 2021; Singh, Deshwal, Kumar, 2021; Palmitessa *et al.*, 2022). Nesse contexto, o uso de modelos de Aprendizado Profundo na

drenagem subsuperficial permite o controle preciso do sistema, minimizando, consequentemente, os riscos de saturação do solo e erosão, ao mesmo tempo em que mantém as condições ideais para o crescimento das culturas (Gumiere *et al.*, 2020; Yang, Chui, 2021).

Técnicas de Aprendizado Profundo têm sido usadas para desenvolver sistemas inteligentes de suporte à decisão, os quais integram dados de múltiplas fontes, como sensores de campo, imagens de satélite e previsões meteorológicas, com a finalidade de prever e recomendar práticas de irrigação e drenagem altamente precisas, o que resulta, por consequência, na gestão mais eficiente dos recursos hídricos e no alcance de maiores produtividades (Sinwar *et al.*, 2019; Bilali; Taleb; Brouziyne, 2021).

4.5 Aplicações utilizando aprendizado generativo

Aprendizado Generativo abre novas possibilidades para simular cenários de irrigação e drenagem, permitindo que pesquisadores e agricultores testem diferentes estratégias de manejo sem a necessidade de intervenções diretas no campo (Goodfellow; Bengio; Courville, 2014).

Modelos generativos, como as Redes Geradoras Adversariais (GANs), podem criar simulações detalhadas de como diferentes práticas de irrigação impactam a produtividade das culturas em condições climáticas (Radford, 2015; Kingma; Welling, 2013). Essas simulações são particularmente úteis para planejar estratégias de longo prazo e para o desenvolvimento de tecnologias de irrigação e drenagem que possam se adaptar às mudanças climáticas (Bowman *et al.*, 2016). Também são importantes para realizar previsões em regiões onde a variabilidade climática é alta e os dados reais são escassos, permitindo uma melhor preparação e planejamento das operações de irrigação e

drenagem (Akkem; Biswas; Varanasi, 2024).

Outra aplicação inovadora é o uso de Aprendizado Generativo para otimizar o design de sistemas de drenagem. Ao gerar múltiplos cenários de fluxo de água e condições do solo, os modelos generativos podem ajudar engenheiros a identificar as configurações mais eficientes para sistemas de drenagem, levando em conta fatores como a topografia do terreno e a permeabilidade do solo (Akkem; Biswas; Varanasi, 2024). Isso não só melhora a eficiência dos sistemas, mas também reduz os custos operacionais e os impactos ambientais.

Além disso, modelos generativos têm sido utilizados para a criação de sistemas de suporte à decisão que ajudam os agricultores a escolher as melhores práticas de irrigação e drenagem com base em cenários futuros simulados. Essas ferramentas fornecem recomendações personalizadas que consideram a dinâmica específica de cada campo, incluindo variáveis climáticas, condições do solo e demandas das culturas. Ao integrar essas simulações com dados em tempo real, os agricultores podem tomar decisões mais informadas e adaptáveis, resultando em uma gestão mais sustentável dos recursos hídricos.

5 CONSIDERAÇÕES FINAIS

Inteligência artificial é um amplo campo de pesquisa que se difundiu na cultura acadêmica e popular, sendo compreendida como qualquer modo de interação entre máquina e ser humano. Nessa interação, a máquina, ao menos aparentemente, aprende a responder o ser humano.

Por ser um campo de estudo extenso, torna-se necessário subdividi-lo em subcampos com conceitos diferenciados, de acordo com suas especificidades, a fim de

evitar o uso indevido em publicações acadêmicas e direcionar o pesquisador para o subcampo que melhor se enquadre ao seu objetivo de estudo.

Ciência de Dados é o subcampo da IA focado na extração de conhecimento a partir de dados e está sendo usado para desenvolver sistemas de apoio à decisão voltados à gestão integrada de sistemas de irrigação e drenagem. Nele há a combinação de dados em tempo real com modelos preditivos para otimização do uso dos recursos hídricos.

Já o Aprendizado de Máquina é um subcampo da IA que cria modelos para aprender padrões e fazer previsões, sendo o Aprendizado Estatístico um subcampo do Aprendizado de Máquina, o qual é baseado em métodos estatísticos para realizar inferências e previsões. Estudos que utilizam técnicas estatísticas, como regressão linear e modelos de séries temporais, têm sido fundamentais para otimizar o design de sistemas de drenagem e prever o impacto das mudanças climáticas sobre a eficiência da drenagem.

Aprendizado Profundo é o subcampo da IA em que ocorre o uso de redes neurais com múltiplas camadas para aprender representações complexas. É particularmente útil no processamento de grandes volumes de dados de imagens de satélite e sensores de campo para monitorar a saúde das culturas e a eficiência da irrigação. Redes neurais profundas podem ser treinadas para detectar padrões em dados de imagens, como áreas com deficiência hídrica ou problemas de drenagem, facilitando intervenções rápidas e precisas. Esse tipo de análise é crucial para a agricultura em larga escala nas regiões tropicais do Brasil, onde as condições de campo podem mudar rapidamente.

Por fim, o Aprendizado Generativo representa um subcampo da IA cujo foco é a criação de novos dados a partir de modelos que entendem a distribuição dos dados existentes. Ele permite a ampliação de bases

de dados pequenas e médias para melhorar o treinamento de modelos de Aprendizado de Máquina, Aprendizado Estatístico e Aprendizado Profundo.

6 REFERÊNCIAS

- ABIOYE, E. A.; HENSEL, O.; ESAU, T. J.; ELIJAH, O.; ABIDIN, M. S. Z.; AYOBAMI, A. S.; NASIRAHMADI, A. Precision irrigation management using machine learning and digital farming solutions. **AgriEngineering**, Basel, v. 4, n. 1, p. 70-103, 2022. DOI: <https://doi.org/10.3390/agriengineering4010006>. Disponível em: <https://www.mdpi.com/2624-7402/4/1/6>. Acesso em: 4 nov. 2024.
- AKKEM, Y.; BISWAS, S. K.; VARANASI, A. A comprehensive review of synthetic data generation in smart farming by using variational autoencoder and generative adversarial network. **Engineering Applications of Artificial Intelligence**, New York, v. 131, article 107881, p. 1-18, 2024. DOI: <https://doi.org/10.1016/j.engappai.2024.107881>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0952197624000393>. Acesso em: 4 nov. 2024.
- BENGIO, Y.; COURVILLE, A.; GOODFELLOW, I. **Deep learning**. Cambridge: MIT Press, 2016.
- BILALI, A.; TALEB, A.; BROUZIYNE, Y. Groundwater quality forecasting using machine learning algorithms for irrigation purposes. **Agricultural Water Management**, New York, v. 245, article 106625, p. 1-13, 2021. DOI: <https://doi.org/10.1016/j.agwat.2020.106625>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0952197624000393>.

le/pii/S0378377420321727. Acesso em: 4 nov. 2024.

BISHOP, C. M. **Pattern recognition and machine learning**. New York: Springer, 2006.

BOWMAN, S. R.; VILNIS, L.; VINYALS, O.; DAI, A. M.; JOZEFOWICZ, R.; BENGIO, S. Generating sentences from a continuous space. *In: SIGNLL CONFERENCE ON COMPUTATIONAL NATURAL LANGUAGE LEARNING*, 20., 2016, Pequim. **Proceedings** [...]. Pequim: CONLL, 2016. v. 1, p. 10-21.

COX, D. R.; HINKLEY, D. V. **Theoretical statistics**. Londres: Chapman and Hall, 1974.

CUN, Y. Deep learning. **Nature**, New York, v. 521, n. 7553, p. 436-444, 2015.

GAO, H.; ZHANGZHONG, L.; ZHENG, W.; CHEN, G. How can agricultural water production be promoted? A review on machine learning for irrigation. **Journal of Cleaner Production**, New York, v. 414, article 137687, p. 1-16, 2023. DOI: <https://doi.org/10.1016/j.jclepro.2023.137687>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0959652623018450>. Acesso em: 4 nov. 2024.

GIMPEL, H.; GRAF-DRASCH, V.; HAWLITSCHKE, F.; NEUMEIER, K. Designing smart and sustainable irrigation: A case study. **Journal of Cleaner Production**, New York, v. 315, article 128048, p. 1-20, 2021. DOI: <https://doi.org/10.1016/j.jclepro.2021.128048>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0959652621022666>. Acesso em: 4 nov. 2024.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep learning**. Cambridge: MIT Press, 2016.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. Generative adversarial nets. **Advances in Neural Information Processing Systems**, Quebec, v. 27, p. 2672-2680, 2014. Disponível em: https://proceedings.neurips.cc/paper_files/paper/2014/hash/5ca3e9b122f61f8f06494c97b1afccf3-Abstract.html. Acesso em: 4 nov. 2024.

GUMIERE, S. J.; CAMPORESE, M.; BOTTO, A.; LAFOND, J. A.; PANICONI, C.; GALLICHAND, J.; ROUSSEAU, A. N. Machine learning vs. physics-based modeling for real-time irrigation management. **Frontiers in Water**, London, v. 2, p. 1-8, 2020. DOI: <https://doi.org/10.3389/frwa.2020.00008>. Disponível em: <https://www.frontiersin.org/journals/water/articles/10.3389/frwa.2020.00008/full>. Acesso em: 4 nov. 2024.

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. **The elements of statistical learning: data mining, inference, and prediction**. 1. ed. New York: Springer, 2009.

HASTIE, T.; TIBSHIRANI, R.; WAINWRIGHT, M. **Statistical learning with sparsity: the lasso and generalizations**. 2. ed. Boca Raton: CRC Press, 2015.

HE, K. Deep residual learning for image recognition. *In: THE IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION*, 1., 2016, Leuven. **Proceedings** [...]. Leuven: CONLL, 2016. v. 1, p. 770-778.

HEMMING, S.; ZWART, F. D.; ELINGS, A.; PETROPOULOU, A.; RIGHINI, I.

Cherry tomato production in intelligent greenhouses—Sensors and AI for control of climate, irrigation, crop yield, and quality.

Sensors, Basel, v. 20, n. 22, article 6430, p. 1-30, 2020. DOI:

<https://doi.org/10.3390/s20226430>.

Disponível em:

<https://www.mdpi.com/1424-8220/20/22/6430>. Acesso em: 4 nov. 2024.

JAYARAMAN, P.; NAGARAJAN, K. K.; PARTHEEBAN, P. A Review on Artificial intelligence Algorithms and Machine Learning to Predict the Quality of Groundwater for Irrigation Purposes. *In: INTERNATIONAL CONFERENCE ON DATA SCIENCE, AGENTS & ARTIFICIAL INTELLIGENCE, 2022, Beijin. Proceedings [...]. Beijin: IEEE, 2022. v. 1, p. 1-8.*

KHADRA, R.; LAMADDALENA, N. Development of a decision support system for irrigation systems analysis. **Water Resources Management**, Amsterdam, v. 24, n. 12, p. 3279-3297, 2010. DOI: <https://doi.org/10.1007/s11269-010-9606-z>. Disponível em: <https://link.springer.com/article/10.1007/s11269-010-9606-z>. Acesso em: 4 nov. 2024.

KINGMA, D. P.; WELLING, M. Auto-encoding variational Bayes. **arXiv preprint arXiv**, Stockholm, n. 1312.6114, 2013. Disponível em: <https://arxiv.org/abs/1312.6114>. Acesso em: 28 ago. 2024.

MITCHELL, M. **Artificial intelligence: a guide for thinking humans**. Nova Iorque: Farrar, Straus and Giroux, 2019.

MOKHTAR, A.; ELBELTAGI, A.; GYASI-AGYEI, Y.; AL-ANSARI, N.; ABDEL-FATTAH, M. K. Prediction of irrigation water quality indices based on machine learning and regression models. **Applied Water Science**, Amsterdam, v. 12,

n. 4, p. 76-89, 2022. DOI:

<https://doi.org/10.1007/s13201-022-01590-x>. Disponível em:

<https://link.springer.com/article/10.1007/s13201-022-01590-x>. Acesso em: 4 nov. 2024.

MURPHY, K. P. **Machine learning: a probabilistic perspective**. Cambridge: MIT Press, 2012.

NILSSON, N. J. **The quest for artificial intelligence**. New York: Cambridge University Press, 2009.

OPPEL, H.; SCHUMANN, A. H. Machine learning based identification of dominant controls on runoff dynamics. **Hydrological Processes**, London, v. 34, n. 11, p. 2450-2465, 2020. DOI:

<https://doi.org/10.1002/hyp.13740>.

Disponível em:

<https://onlinelibrary.wiley.com/doi/10.1002/hyp.13740>. Acesso em: 4 nov. 2024.

PALMITESSA, R.; GRUM, M.; ENGSIG-KARUP, A. P.; LÖWE, R. Accelerating hydrodynamic simulations of urban drainage systems with physics-guided machine learning. **Water Research**, New York, v. 223, article 118972, p. 1-13, 2022. DOI:

<https://doi.org/10.1016/j.watres.2022.118972>. Disponível em:

<https://www.sciencedirect.com/science/article/pii/S0043135422009198>. Acesso em: 4 nov. 2024.

POE, A. **Artificial intelligence in the 21st century**. Boca Raton: CRC Press, 2018.

PROVOST, F.; FAWCETT, T. **Data science for business: what you need to know about data mining and data-analytic thinking**. 1 ed. Sebastopol: O'Reilly Media, 2013.

- RABHI, L.; FALIH, N.; AFRAITES, L.; BOUIKHALENE, B. Digital agriculture based on big data analytics: A focus on predictive irrigation for smart farming in Morocco. *Indonesian Journal of Electrical Engineering and Computer Science*, Jakarta, v. 24, n. 1, p. 581-589, 2021.
- RADFORD, A. Unsupervised representation learning with deep convolutional generative adversarial networks. *arXiv preprint*, Stockholm, n. 1511.06434, 2015. DOI: <https://doi.org/10.48550/arXiv.1511.06434>. Disponível em: <https://arxiv.org/abs/1511.06434>. Acesso em: 4 nov. 2024.
- SARALA, S. M. Robust smart irrigation system using hydroponic farming based on data science and IoT. *In: IEEE BANGALORE HUMANITARIAN TECHNOLOGY CONFERENCE, 2020, Beijin. Proceedings [...]*. Beijin: IEEE, 2020. v. 1, p. 1-4.
- SAYARI, S.; MAHDAVI-MEYMAND, A.; ZOUNEMAT-KERMANI, M. Irrigation water infiltration modeling using machine learning. *Computers and Electronics in Agriculture*, New York, v. 180, article 105921, p. 1-9, 2021. DOI: <https://doi.org/10.1016/j.compag.2020.105921>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0168169920331264>. Acesso em: 4 nov. 2024.
- SCHMIDHUBER, J. Deep learning in neural networks: an overview. *Neural Networks*, Stockholm, v. 61, p. 85-117, 2015. DOI: <https://doi.org/10.48550/arXiv.1404.7828>. Disponível em: <https://arxiv.org/abs/1404.7828>. Acesso em: 4 nov. 2024.
- SCHUTT, R.; O'NEIL, C. **Doing data science: straight talk from the frontline**. 1. ed. Sebastopol: O'Reilly Media, 2013.
- SILVERMAN, B. W. **Density estimation for statistics and data analysis**. London: Chapman and Hall, 1986.
- SINGH, G.; SINGH, J.; WANI, O. A.; EGBUERI, J. C.; AGBASI, J. C. Assessment of groundwater suitability for sustainable irrigation: a comprehensive study using indexical, statistical, and machine learning approaches. *Groundwater for Sustainable Development*, New York, v. 24, article 101297, p. 1-23, 2024. DOI: <https://doi.org/10.1016/j.gsd.2024.101297>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2352801X24002200>. Acesso em: 4 nov. 2024.
- SINGH, R.; DESHWAL, A.; KUMAR, K. Implementation of smart irrigation system using intelligent systems and machine learning approaches. *In: DATA SCIENCE AND INNOVATIONS FOR INTELLIGENT SYSTEMS, 2021, Boca Raton. Proceedings [...]*. Boca Raton: CRC Press, 2021. v. 1, p. 299-318.
- SINWAR, D.; DHAKA, V. S.; SHARMA, M. K.; RANI, G. AI-Based Yield Prediction and Smart Irrigation. *Internet of Things and Analytics for Agriculture*, New York, v. 67, n. 2, p. 155-180, 2019. DOI: https://doi.org/10.1007/978-981-15-0663-5_8. Disponível em: https://link.springer.com/chapter/10.1007/978-981-15-0663-5_8. Acesso em: 4 nov. 2024.
- UMUTONI, L.; SAMADI, V. Application of machine learning approaches in supporting irrigation decision making: A review. *Agricultural Water Management*, New York, v. 294, article 108710, p. 1-14,

2024. DOI:

<https://doi.org/10.1016/j.agwat.2024.108710>.

Disponível em:

<https://www.sciencedirect.com/science/article/pii/S0378377424000453>. Acesso em: 4

nov. 2024.

WICKHAM, H.; GROLEMUND, G. **R for data science**: import, tidy, transform, visualize, and model data. Sebastopol: O'Reilly Media, 2016.

YANG, Y.; CHUI, T. F. M. Modeling and interpreting hydrological responses of sustainable urban drainage systems with explainable machine learning methods.

Hydrology and Earth System Sciences, Paris, v. 25, n. 11, p. 5839-5858, 2021.

DOI: <https://doi.org/10.5194/hess-25-5839-2021>. Disponível em:

<https://hess.copernicus.org/articles/25/5839/2021/>. Acesso em: 4 nov. 2024.