



DESAFIOS E SOLUÇÕES NO ENSINO DO AGRONEGÓCIO: A INTEGRAÇÃO DA INTELIGÊNCIA ARTIFICIAL AO CURRÍCULO

DOI: 10.37702/2175-957X.COBENGE.2025.6174

Autores: KAMILA CRISTINA DE CREDO ASSIS, JANE PIANTONI, WELITON DO CARMO RODRIGUES, RODRIGO FERRAZ AZEVEDO

Resumo: O avanço das tecnologias digitais transformou profundamente o setor agrícola, exigindo novas competências dos profissionais da área. Nesse contexto, este estudo apresenta o design e a implementação de um curso de curta duração intitulado “Agricultura 4.0: Otimizando com Inteligência Artificial”, voltado à capacitação de estudantes e profissionais do agronegócio no uso da Inteligência Artificial (IA) aplicada à produção agrícola. A abordagem pedagógica foi fundamentada na Aprendizagem Baseada em Problemas (PBL) e em metodologias ativas, com ênfase na integração entre teoria e prática por meio de atividades contextualizadas e do uso de bases de dados agrícolas reais. O curso foi estruturado em cinco módulos, totalizando 20 horas, abordando desde os fundamentos da agricultura digital, estatística e programação em Python até técnicas avançadas como aprendizagem supervisionada, análise de séries temporais, visão computacional e aprendizagem por reforço. As atividades práticas foram realizadas

Palavras-chave: Agricultura Digital, Inteligência Artificial, Aprendizagem Baseada em Projetos

DESAFIOS E SOLUÇÕES NO ENSINO DO AGRONEGÓCIO: A INTEGRAÇÃO DA INTELIGÊNCIA ARTIFICIAL AO CURRÍCULO

1 INTRODUÇÃO

A crescente complexidade do mercado de trabalho tem exigido dos estudantes universitários, especialmente aqueles voltados ao setor do agronegócio, uma formação que alie sólida base teórica a experiências práticas. As empresas demandam profissionais preparados para lidar com desafios reais, com domínio de tecnologias emergentes e capacidade de atuação em ambientes dinâmicos. Nesse contexto, a engenharia aplicada ao agronegócio destaca-se como um campo estratégico para o desenvolvimento econômico e sustentável do país (BLACKIE et al., 2016), exigindo formas inovadoras de ensino que aproximem a formação acadêmica da realidade do setor.

Entre os conhecimentos mais valorizados atualmente no ambiente rural, destaca-se a capacidade de aplicar novas tecnologias às atividades agropecuárias. Nesse cenário, a Inteligência Artificial (IA) tem ganhado protagonismo por seu potencial de transformar práticas agrícolas, como a detecção automatizada de pragas, doenças e o mapeamento de áreas produtivas (ASSIS; PIANTONI; FERRAZ, 2024). Incorporar essa tecnologia ao processo formativo torna-se, assim, essencial para alinhar a formação acadêmica às demandas contemporâneas do agronegócio.

Apesar dos avanços na educação, as Instituições de Ensino Superior (IES) ainda enfrentam desafios significativos para integrar, de forma eficaz, teoria e prática nos currículos. Muitos cursos continuam ancorados em modelos tradicionais, com ênfase excessiva na transmissão teórica de conteúdos e pouco espaço para atividades práticas e interdisciplinares. Essa lacuna entre o ensino acadêmico e as demandas do mercado contribui para a dificuldade de inserção dos egressos no mundo do trabalho.

Pesquisas como a de Björck (2021) evidenciam que metodologias de aprendizagem integradas ao contexto profissional, centradas no estudante e baseadas em problemas, são mais eficazes para o desenvolvimento de competências como autonomia, colaboração e capacidade de resolver problemas complexos. Abordagens como a Aprendizagem Baseada em Problemas (Problem-Based Learning – PBL), descrita por Benjamin e Keenan (2006), e o ciclo construtivista proposto por Carvalho, Porto e Belhot (2001), destacam-se por promoverem uma conexão mais efetiva entre teoria e prática, estimulando o pensamento crítico e a resolução de desafios reais.

Diante desse cenário, este trabalho tem como objetivo apresentar a estruturação de um curso livre de curta duração voltado à aplicação da Inteligência Artificial no agronegócio, detalhando sua proposta pedagógica, os métodos utilizados e a forma como foram integradas atividades práticas e interativas para promover uma aprendizagem significativa e alinhada às exigências do setor.

2 REFERENCIAL TEÓRICO

2.1 IA aplicada ao Agronegócio

A Inteligência Artificial (IA), embora tenha suas origens nas décadas de 1950, ganhou destaque recente com o avanço de tecnologias complementares como IoT e Big Data (MORETI et al., 2021). No agronegócio, a IA tem se mostrado uma aliada estratégica na modernização das práticas produtivas, atuando desde a coleta e análise de dados até o suporte à tomada de decisões (KAPLAN; HAENLEIN, 2019; TEIXEIRA, 2014). Seu diferencial está na capacidade de lidar com grandes volumes de dados, oferecendo agilidade, precisão e adaptabilidade aos sistemas produtivos.

As abordagens práticas de IA no campo podem ser classificadas em dois eixos principais: replicar a capacidade humana em decisões complexas ou superá-la em eficiência e exatidão (MEGETO et al., 2020). Para isso, os sistemas precisam receber dados provenientes de sensores IoT, satélites ou estações meteorológicas, realizando análises em tempo real, previsões e ações autônomas (HUTSON, 2017). Esse processamento inteligente contribui para a redução de custos, otimização de recursos e aumento da sustentabilidade das lavouras (TALAVIYA et al., 2020).

O setor agrícola, altamente dependente de fatores ambientais, mão de obra e insumos, tem buscado na IA e em startups tecnológicas uma forma de reduzir incertezas e aumentar a produtividade. Aplicações como drones, softwares de monitoramento e sensores inteligentes têm atraído investidores e fomentado um mercado crescente de inovação (ZHAI et al., 2020).

Entre as ferramentas de destaque, está a Visão Computacional, que simula a percepção humana a partir de imagens captadas por câmeras ou sensores, permitindo o monitoramento da lavoura, detecção de anomalias e automação de processos agrícolas como a colheita e o controle de plantas daninhas (MAVRIDOU et al., 2019; SUN et al., 2017). No entanto, o sucesso dessas aplicações depende da disponibilidade de conjuntos de dados de imagens em condições reais de campo. Felizmente, colaborações entre instituições têm impulsionado a criação e o compartilhamento desses bancos de dados, estimulando avanços em áreas como fenologia e taxonomia (HESTAND et al., 2020).

Outra vertente essencial é o Aprendizado de Máquina (ML), que permite que os sistemas aprendam padrões e tomem decisões com base em dados históricos, sem necessidade de programação explícita (PATIL; BANYAL, 2019). Essa tecnologia tem sido aplicada na análise multivariada de fatores que afetam a produção, como clima, solo, água e preços, oferecendo suporte à escolha de cultivos e otimização da produtividade (HEIN; SILVA, 2019; SCHNFELD et al., 2018).

Dessa forma, a IA aplicada ao agro representa uma evolução no modo de produzir, possibilitando decisões mais inteligentes, sustentáveis e rentáveis, e consolidando um mercado promissor e em rápida expansão.

2.2 Técnicas de Aprendizagem para Cursos Baseados em Problemas (PBP)

A educação contemporânea tem priorizado metodologias que promovem o protagonismo discente e a construção ativa do conhecimento. Nesse cenário, a Aprendizagem Baseada em Problemas (ABP), também conhecida como *Problem-Based Learning* (PBL), tem se destacado como uma abordagem centrada no estudante, em que a aprendizagem é estimulada por situações-problema autênticas, contextualizadas e desafiadoras (DOLMANS et al., 2016).

Reconhecida como uma das metodologias ativas mais eficazes, especialmente em cursos técnicos, tecnológicos e superiores, a ABP promove uma aprendizagem significativa ao envolver os estudantes em processos de investigação, colaboração e reflexão crítica sobre problemas complexos do mundo real (LOYENS; JONES; MIKKERS, 2022).

A base teórica da ABP está fortemente enraizada nos princípios do construtivismo, especialmente nas obras de Piaget (1976), que defende a importância das interações entre sujeito e ambiente para o desenvolvimento cognitivo, e de Vygotsky (1978), que ressalta a mediação social, a linguagem e a zona de desenvolvimento proximal como elementos fundamentais para a aprendizagem colaborativa.

Entre as técnicas pedagógicas que complementam e potencializam o modelo da ABP, destacam-se:

- **Aprendizagem Ativa:** Os estudantes são protagonistas de seu aprendizado, participando ativamente da investigação, experimentação e análise crítica dos problemas propostos, o que favorece o desenvolvimento de competências cognitivas e metacognitivas (FREEMAN et al., 2014).
- **Aprendizagem Colaborativa:** A resolução de problemas ocorre de forma coletiva, promovendo trocas de saberes, empatia, escuta ativa e habilidades socioemocionais essenciais no contexto contemporâneo (DILLENBOURG, 2021).
- **Estudos de Caso:** Permitem a aproximação com contextos reais e multifacetados, nos quais os estudantes formulam hipóteses, testam soluções e analisam os resultados com base em evidências (KIM; SHARMA; LAND, 2020).
- **Autorregulação da Aprendizagem:** Os estudantes são incentivados a planejar, monitorar e avaliar seu próprio processo de aprendizagem, promovendo autonomia e consciência metacognitiva (PANADERO, 2017).

Outro elemento central no modelo ABP é o papel do facilitador. Ao contrário do professor tradicional, o facilitador atua como mediador, orientando o processo investigativo, incentivando a curiosidade, promovendo a autorreflexão e auxiliando na identificação de lacunas conceituais (AZER, 2019).

Além disso, a incorporação de tecnologias digitais e ambientes virtuais de aprendizagem tem ampliado as possibilidades de aplicação da ABP, sobretudo em contextos híbridos e a distância. Ferramentas como Google Colab, repositórios abertos de dados, simuladores, ambientes de programação colaborativa e plataformas gamificadas tornam a aprendizagem mais interativa, dinâmica e personalizada (REDECKER, 2017).

3 MATERIAL E MÉTODOS

A estruturação do curso livre “**Agricultura 4.0: Otimizando com Inteligência Artificial**” foi conduzida de forma sistemática e colaborativa, com o objetivo de criar uma trilha formativa prática, acessível e alinhada às demandas emergentes do setor agropecuário. O curso foi idealizado para atender profissionais, estudantes e técnicos do agronegócio interessados em compreender os fundamentos da Inteligência Artificial (IA) e aplicá-los a contextos reais de produção. Para tanto, a metodologia de criação do curso compreendeu cinco etapas interdependentes: elaboração do plano de aula, construção do currículo, desenvolvimento da apostila, produção de slides e criação de materiais complementares de apoio.

No que se refere à definição do currículo, adotou-se uma progressão modular composta por oito unidades temáticas, organizadas de forma gradual e estratégica. Essa estrutura inicia com a contextualização histórica da agricultura digital e os fundamentos da IA, avançando até

a aplicação prática de algoritmos de aprendizado supervisionado, séries temporais, visão computacional e aprendizado por reforço. Cada módulo foi desenvolvido com base em competências específicas, atentando-se às exigências contemporâneas do setor agropecuário, como a análise de grandes volumes de dados e a predição de variáveis críticas relacionadas à produção agrícola.

O método de ensino empregado no curso fundamentou-se na integração de estratégias de aprendizagem ativa, aprendizagem baseada em problemas (PBL) e no uso de recursos digitais amplamente acessíveis. Visando garantir a compreensão por parte de alunos com diferentes níveis de familiaridade com programação ou ciência de dados, os conteúdos foram apresentados em linguagem clara e estruturados de maneira a facilitar a assimilação progressiva dos conceitos. A abordagem pedagógica buscou, portanto, equilibrar teoria e prática ao longo dos módulos temáticos.

Nesse sentido, os conteúdos foram organizados de forma progressiva, partindo de noções introdutórias sobre agricultura digital e os princípios fundamentais da IA até a implementação de modelos preditivos com ferramentas práticas. A linguagem de programação Python foi incorporada desde os primeiros módulos, tendo o Google Colab como principal ambiente de codificação. A apresentação da linguagem seguiu uma lógica didática, com exemplos contextualizados na rotina do campo, trechos de código comentados e explicações visuais que favorecem o entendimento do funcionamento dos algoritmos.

A articulação entre teoria e prática foi reforçada pela seleção criteriosa dos conjuntos de dados utilizados nas atividades. Os datasets foram escolhidos com base em sua relevância prática e facilidade de acesso, priorizando fontes públicas e abertas. Os dados contemplaram diferentes aspectos do setor agropecuário, como plantio, colheita, características do solo, condições climáticas e fitossanitárias, possibilitando a simulação de cenários reais enfrentados no campo. Esses conjuntos de dados foram empregados na construção e no treinamento de modelos de regressão, classificação e previsão, permitindo aos alunos vivenciar a aplicação concreta das técnicas de IA no agronegócio.

4 RESULTADOS E DISCUSSÃO

A execução da proposta do curso fez uso da carga horária total de 20 horas, distribuída ao longo de cinco dias, com sessões diárias de quatro horas. A cada dia o conteúdo combinou teoria e prática, com a utilização de exemplos e conjuntos de dados reais do setor agropecuário, com o intuito de facilitar a assimilação dos conceitos de inteligência artificial, em especial das técnicas do Aprendizado de Máquina.

A metodologia adotada estruturou os conteúdos em blocos de conhecimento, promovendo o desenvolvimento progressivo das competências técnicas e reforçando a conexão entre teoria e aplicação prática. O uso de variáveis como temperatura média, volume de água por hectare e presença de pragas mostrou-se especialmente eficaz para estimular o engajamento dos participantes e favorecer a aplicação do conhecimento em seus contextos profissionais.

O **primeiro módulo de conhecimento**, desenvolvido no primeiro dia do curso teve como foco a introdução aos fundamentos da agricultura digital e à programação em Python. Inicialmente, foram discutidos os marcos históricos da agricultura, os desafios contemporâneos do setor e o papel da IA na chamada Agricultura 4.0. Em seguida, os participantes foram introduzidos aos conceitos fundamentais da linguagem Python, com o objetivo de nivelar o conhecimento dos participantes que ainda não possuíam habilidades de programação. Foram abordados conceitos como variáveis, operações aritméticas, estruturas condicionais, de repetição e lógicas, além de funções e definição de classes (VANDERPLAS, 2016). De acordo com a Figura 1, os exemplos de variáveis e situações utilizados em aula,

remetem a situações reais do campo e introduzem os fundamentos da programação de forma acessível e aplicada. Ao final, foi proposta uma atividade avaliativa composta por desafios práticos no ambiente Google Colab, permitindo aos alunos exercitarem os conhecimentos adquiridos de forma ativa.

Figura 1 – Variáveis e estrutura condicional em Python

```
# Variáveis de exemplo para condições climáticas
chuva_esperada = False
temperatura = 35 # temperatura em graus Celsius

# Verificação de condições climáticas para determinar a necessidade de irrigação
if chuva_esperada:
    print("Não é necessário irrigar hoje.")
elif temperatura > 30:
    print("Irrigação intensificada devido ao calor extremo.")
else:
    print("Irrigação normal necessária hoje.")
```

Fonte: Elaboração própria.

Após a introdução à linguagem Python, os alunos participaram, ainda dentro do primeiro módulo, de uma aula dedicada à revisão de conceitos fundamentais de estatística aplicados à ciência de dados. Foram abordados temas como população e amostra, distribuição de frequência, medidas de posição e dispersão, correlação, entre outras, essenciais para a análise e interpretação de dados em contextos reais. No cenário agrícola, por exemplo, compreender a correlação entre variáveis como temperatura e produtividade, ou reconhecer padrões em amostras de solo, pode orientar ações mais assertivas. Durante as atividades, os alunos também tiveram contato com as bibliotecas Pandas e NumPy, voltadas a manipulação de dados e no suporte a análises estatísticas em Python (MCKINNEY, 2017).


O segundo bloco de conhecimento, desenvolvido no segundo dia do curso, marcou o início da imersão dos participantes em técnicas de Aprendizado Supervisionado. Nesse módulo os alunos exploraram algoritmos de regressão e classificação utilizando a biblioteca Scikit-learn (PEDREGOSA et al., 2011), com foco nos métodos de Regressão Linear, Árvores de Regressão, K-Nearest Neighbors (K-NN) e Árvores de Decisão. As atividades práticas foram conduzidas com conjuntos de dados reais do setor agrícola, como o Tomato Plant Disease, que apresenta características visuais e ambientais relacionadas à saúde das folhas de tomate, e o Corn Crop Growth, voltado ao crescimento de culturas.

Para avaliar o desempenho dos modelos, foram aplicadas métricas como acurácia, precisão, revocação e matriz de confusão. De modo geral, esse segundo módulo consolidou os fundamentos da modelagem supervisionada, oferecendo aos participantes a oportunidade de construir modelos de predição e classificação com aplicação direta no campo, além de estimular a reflexão sobre os riscos e consequências dos erros de predição em contextos sensíveis, como o manejo de pragas e doenças.

No terceiro dia, os alunos avançaram para o módulo de séries temporais, no qual foram discutidos os fundamentos dessa abordagem e sua importância estratégica para o agronegócio, especialmente no planejamento da produção e antecipação de eventos climáticos (LIU et al., 2024). Foram apresentados modelos estatísticos, com ênfase no ARIMA, amplamente utilizado para modelagem e previsão de séries univariadas (BOX; JENKINS; REINSEL, 2015), e no Prophet, uma ferramenta de código aberto desenvolvida pelo Facebook para previsão automatizada e interpretável (TAYLOR; LETHAM, 2018). As aplicações práticas incluem a previsão de variáveis críticas como produtividade por hectare, volume de irrigação e precipitação acumulada. A Figura 2 (disponível na apostila) exemplifica a aplicação da

modelagem na previsão de produtividade, reforçando o potencial da análise temporal como suporte à tomada de decisão no campo. A discussão final do módulo ressalta a importância da avaliação crítica dos modelos, destacando a incerteza preditiva como fator relevante na gestão de riscos agrícolas. Modelos mal calibrados podem induzir decisões equivocadas no planejamento agrícola, especialmente em contextos de variabilidade climática acentuada.

Figura 2 – Previsão da Produtividade usando Prophet.



Fonte: Elaboração própria.

Nas etapas finais do curso, os alunos foram introduzidos aos fundamentos de Visão Computacional (4º módulo/dia) e Aprendizado por Reforço (5º módulo/dia), com foco na aplicação dessas técnicas ao setor agrícola. No módulo de Visão Computacional, foram apresentadas as arquiteturas de redes neurais convolucionais (CNNs), com atividades práticas voltadas à classificação de imagens relacionadas ao agro. Os alunos trabalharam com bases de dados reais, como imagens de grãos de café para classificação de torrefação, raças de gado e identificação de pragas agrícolas, desenvolvendo modelos capazes de realizar predições a partir de dados visuais. Segundo Duckett et al. (2018), a visão computacional tem um enorme potencial de aplicação no âmbito da agricultura digital, sendo empregada na detecção de doenças e pragas, na estimação de safra e na avaliação não invasiva de atributos como qualidade, aparência e volume.

Já no módulo de Aprendizado por Reforço, foram introduzidos os conceitos fundamentais que sustentam sistemas autônomos, como tratores inteligentes e drones agrícolas. Embora o curso não tenha abordado diretamente o uso desses equipamentos, foram apresentados os fundamentos teóricos do Aprendizado por Reforço, incluindo o Processo de Decisão de Markov (MDP), Q-Learning e o algoritmo SARSA. A crescente adoção de tecnologias autônomas no campo brasileiro é evidenciada por eventos como a Agrishow 2025, onde foram apresentados drones de pulverização com capacidades de até 70 litros, capazes de operar de forma autônoma e ajustar sua operação ao relevo, otimizando a aplicação e reduzindo a complexidade nas manobras (Agro Estadão, 2025).

A inclusão desses dois módulos visou expandir a compreensão dos participantes sobre o espectro das soluções baseadas em IA, aproximando-os de cenários reais de inovação no setor agropecuário. O curso reforçou a importância da integração entre teoria e prática, não apenas no domínio técnico, mas também no desenvolvimento do pensamento crítico sobre as implicações do uso da IA no campo — como o custo de implementação, as limitações operacionais em áreas remotas e as questões éticas associadas à substituição de mão de obra humana por sistemas autônomos.

De modo geral, a proposta formativa buscou engajar os participantes com atividades contextualizadas, permitindo-lhes visualizar a aplicabilidade das técnicas aprendidas em desafios concretos do agro. Alinhado ao pensamento de Dewey (1997), que defende a aprendizagem como um processo experiencial, o curso criou condições para que os alunos se apropriassem dos conceitos de forma significativa, ampliando sua capacidade de atuação na agricultura digital de forma crítica, ética e tecnicamente embasada.

5 CONCLUSÃO

A experiência relatada com o curso livre “Agricultura 4.0: Otimizando com Inteligência Artificial” demonstrou que é possível promover uma formação alinhada às exigências contemporâneas do agronegócio por meio da integração entre teoria e prática, com ênfase na aplicação de tecnologias emergentes. A estruturação modular do curso, aliada ao uso de metodologias ativas como a PBP, favoreceu o desenvolvimento de competências técnicas, analíticas e reflexivas, aproximando os participantes de contextos reais e desafiadores do setor agropecuário.

A utilização de ferramentas acessíveis, como a linguagem Python e o ambiente Google Colab, bem como a seleção criteriosa de conjuntos de dados relacionados à rotina do campo, contribuiu para uma aprendizagem significativa, contextualizada e aplicável. Os módulos temáticos abordaram desde fundamentos estatísticos e algoritmos supervisionados até séries temporais, visão computacional e aprendizado por reforço, consolidando uma trilha formativa que estimula a autonomia, o pensamento crítico e a capacidade de resolução de problemas complexos no ambiente rural.

Dessa forma, conclui-se que a proposta pedagógica adotada alcançou seu objetivo de aproximar a formação acadêmica da realidade do agronegócio digital. A experiência formativa descrita neste trabalho reforça a importância de iniciativas educacionais que articulem conhecimentos interdisciplinares, práticas contextualizadas e tecnologias digitais, contribuindo para a construção de uma educação mais conectada às demandas do setor e comprometida com a inovação e a sustentabilidade no campo.

AGRADECIMENTOS

Este projeto foi apoiado pelo programa PPI Softex, Termo de Parceria Nº 251/SOFTEX/FIT/TIC 47, financiado pelo Ministério da Ciência, Tecnologia e Inovações com recursos da Lei nº 8.248/91.

REFERÊNCIAS

AGRO ESTADÃO. Agrishow 2025 terá maior drone de pulverização do Brasil. 2025. Disponível em: <https://agro.estadao.com.br/agrishow-2025/agrishow-2025-tera-maior-drone-de-pulverizacao-do-brasil>. Acesso em: 9 maio 2025.

AZER, S. A. The facilitator's role in PBL: impacts on student learning. **Medical Teacher**, v. 41, n. 5, p. 551–557, 2019.

BJÖRCK, V. Taking issue with how the Work-integrated Learning discourse ascribes a dualistic meaning to graduate employability. **High Education**, 2021.

BLACKIE, M.; LE ROUX, K.; MCKENNA, S. Possible futures for science and engineering education. **High Education**, v. 71, p. 755-766, 2016.

BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. Time series analysis: forecasting and control. 5. ed. Hoboken: Wiley, 2015.

DEWEY, J. Experiência e educação. São Paulo: Martins Fontes, 1997.

DILLENBOURG, P. **Orchestration Graphs: Modeling scalable education**. Cham: Springer, 2021.

DOLMANS, D. H. J. M. et al. Deep and surface learning in problem-based learning: a review of the literature. **Advances in Health Sciences Education**, v. 21, p. 1087–1112, 2016.

DUCKETT, T. et al. Visão computacional aplicada na agricultura. In: AGRICULTURA DIGITAL. Campinas: Embrapa Informática Agropecuária, 2018. p. 123–145. Disponível em: <https://www.alice.cnptia.embrapa.br/alice/bitstream/doc/1126261/1/LV-Agricultura-digital-2020-cap6.pdf>. Acesso em: 9 maio 2025.

FREEMAN, S. et al. Active learning increases student performance in science, engineering, and mathematics. **Proceedings of the National Academy of Sciences**, v. 111, n. 23, p. 8410–8415, 2014.

HEIN, L.; SILVA, A. G. da. Machine learning na agricultura: uma revisão das aplicações no Brasil. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 23, n. 2, p. 138–143, 2019.

HESTAND, R. S.; ECKELS, S.; KAY, S.; TAYLOR, C. Automatic plant taxonomy using deep learning. **Computers and Electronics in Agriculture**, v. 175, 105605, 2020.

HUTSON, M. Artificial intelligence: The AI doctor will see you now. **Science**, v. 357, n. 6346, p. 18–23, 2017.

KAPLAN, A.; HAENLEIN, M. Siri, Siri, in my hand: Who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence. **Business Horizons**, v. 62, n. 1, p. 15–25, 2019.

KIM, M. K.; SHARMA, P.; LAND, S. M. Examining the effects of case-based learning on students' problem-solving skills in a mobile learning environment. **Educational Technology Research and Development**, v. 68, p. 1157–1179, 2020.

LIU, G.; ZHONG, K.; LI, H.; CHEN, T.; WANG, Y. A state of art review on time series forecasting with machine learning for environmental parameters in agricultural greenhouses. **Information Processing in Agriculture**, [S.l.], v. 11, n. 2, p. 143-162, 2024. DOI: 10.1016/j.inpa.2022.10.005.

LOYENS, S. M. M.; JONES, S. H.; MIKKERS, J. Problem-based learning as a promising approach in higher education: exploring the evidence. In: SAWYER, R. K. (ed.). **The Cambridge handbook of the learning sciences**. 2. ed. Cambridge: Cambridge University Press, 2022.

MAVRIDOU, E.; ANDREADIS, S.; MOSHOU, D.; BOCHTIS, D. Weed detection based on image processing and supervised classification techniques. **Computers and Electronics in Agriculture**, v. 165, 104963, 2019.

MCKINNEY, W. Python for Data Analysis: data wrangling with pandas, NumPy, and IPython. 2. ed. Sebastopol: O'Reilly Media, 2017.

MEGETO, A. M.; GLERIANI, J. M.; OLIVEIRA, M. S. de; GLERIANI, C. M. Inteligência Artificial e Aprendizado de Máquina na Agricultura: Uma Revisão Sistemática. **Revista Agrogeoambiental**, v. 12, n. 3, p. 47–63, 2020.

MORETI, D.; COSTA, L. A. F.; LIMA, M. A. C.; MORAIS, M. M. Inteligência artificial aplicada ao agronegócio. **Revista Científica Multidisciplinar Núcleo do Conhecimento**, v. 8, n. 1, p. 145–164, 2021.

PANADERO, E. A review of self-regulated learning: six models and four directions for research. **Frontiers in Psychology**, v. 8, p. 422, 2017.

PATIL, K. A.; BANYAL, R. K. Machine Learning and its Applications in Agriculture. **International Journal of Advanced Research in Computer and Communication Engineering**, v. 8, n. 5, p. 73–76, 2019.

PEDREGOSA, F. et al. Scikit-learn: Machine learning in Python. **Journal of Machine Learning Research**, v. 12, p. 2825–2830, 2011.

PIAGET, J. **A epistemologia genética**. São Paulo: Abril Cultural, 1976.

REDECKER, C. **European Framework for the Digital Competence of Educators: DigCompEdu**. Luxembourg: Publications Office of the European Union, 2017.

SCHMIDT, H. G. et al. Twelve tips for implementing problem-based learning. **Medical Teacher**, v. 31, n. 9, p. 794-799, 2009.

SCHNFELD, M. A.; LIMA, D. C.; TOMAZ, R. S.; BORGES, L. G. Modelagem estatística aplicada ao rendimento de grãos de soja: uma abordagem multivariada. **Revista de Agricultura Neotropical**, v. 5, n. 4, p. 39–45, 2018.

SUN, Y.; ZHANG, G.; YANG, G.; WANG, J.; FENG, H.; ZHAO, X. Computer vision technology in agricultural automation — A review. **Information Processing in Agriculture**, v. 4, n. 3, p. 241–251, 2017.

TALAVIYA, T.; SHAH, D.; PATEL, N.; YAGNIK, H.; SHAH, M. Implementation of artificial intelligence in agriculture for optimization of irrigation and application of pesticides and herbicides. **Artificial Intelligence in Agriculture**, v. 4, p. 58–73, 2020.

TAYLOR, S. J.; LETHAM, B. Forecasting at scale. *The American Statistician*, v. 72, n. 1, p. 37–45, 2018. DOI: 10.1080/00031305.2017.1380080.

TEIXEIRA, M. A. Inteligência artificial e agricultura de precisão: a nova revolução verde. **Ciência Hoje**, v. 52, n. 308, p. 58–61, 2014.

VANDERPLAS, J. Python data science handbook: essential tools for working with data. Sebastopol: O'Reilly Media, 2016.

VYGOTSKY, L. S. **A formação social da mente**. São Paulo: Martins Fontes, 1978.

ZHAI, Z.; MARTÍNEZ, J. F.; BELTRAN, V.; MARTÍNEZ, N. Decision support systems for agriculture 4.0: Survey and challenges. **Computers and Electronics in Agriculture**, v. 170, 105256, 2020.

CHALLENGES AND SOLUTIONS IN AGRIBUSINESS EDUCATION: INTEGRATING ARTIFICIAL INTELLIGENCE INTO THE CURRICULUM

Abstract: The advancement of digital technologies has profoundly transformed the agricultural sector, requiring new skills from professionals in the field. In this context, this study presents the design and implementation of a short course entitled “Agriculture 4.0: Optimizing with Artificial Intelligence,” aimed at training students and agribusiness professionals in the use of Artificial Intelligence (AI) applied to agricultural production. The pedagogical approach was based on Problem-Based Learning (PBL) and active learning, emphasizing the integration of theory and practice through contextualized activities and the use of real-world agricultural datasets. The course was structured into five modules over a total of 20 hours, covering topics from digital agriculture foundations, statistics, and Python programming to advanced techniques such as supervised learning, time series analysis, computer vision, and reinforcement learning. Practical activities were conducted in the Google Colab® environment using libraries such as Pandas, NumPy, Scikit-learn, and Prophet, with applications in real scenarios like pest detection, yield forecasting, and agricultural image classification. The results demonstrate that integrating AI into the curriculum fosters meaningful learning, promotes critical thinking, and prepares participants for the challenges of Agriculture 4.0. The use of active methodologies and accessible technologies proved effective in building technical and analytical competencies. It is concluded that educational experiences of this nature are essential to aligning academic training with the current demands of the agricultural sector, promoting innovation, sustainability, and employability.

Keywords: Digital Agriculture, Artificial Intelligence, Problem-Based Learning, Professional Training.

