



Inteligência artificial na agricultura com aplicabilidade no setor sementeiro

Artificial intelligence in agriculture with applicability in the seeding sector

Romário de Mesquita Pinheiro¹, Gizele Ingrid Gadotti^{2,1},
Rita de Cassia Mota Monteiro¹, Ruan Bernardy²

⁽¹⁾Orcid ID: <https://orcid.org/0000-0003-0484-8351>, Faculdade de Agronomia Eliseu Maciel- Universidade Federal de Pelotas, doutorando do Programa de Pós-Graduação em Ciência e Tecnologia de Sementes, Pelotas-RS, Brasil. E-mail: romario.ufacpz@hotmail.com

^(2,1)Orcid ID: <https://orcid.org/0000-0001-9545-6577>, Centro de Engenharia- CENG, Universidade Federal de Pelotas, Professora do Programa de Pós-Graduação em Ciência e Tecnologia de Sementes, Pelotas-RS, Brasil. E-mail: gizeleingrid@gmail.com

⁽¹⁾Orcid ID: <https://orcid.org/0000-0001-9342-2779>, Faculdade de Agronomia Eliseu Maciel- Universidade Federal de Pelotas, mestranda do Programa de Pós-Graduação em Ciência e Tecnologia de Sementes, Pelotas-RS, Brasil. E-mail: ritamonteiro@gmail.com

⁽²⁾Orcid ID: <https://orcid.org/0000-0001-9285-1993>, Centro de Engenharia- CENG, Universidade Federal de Pelotas, Mestrando de Pós Graduação em Ciências Ambientais, Pelotas-RS, Brasil. E-mail: ruanbernardy@yahoo.com.br

Todo o conteúdo expresso neste artigo é de inteira responsabilidade dos seus autores.

Recebido em: 05/04/2021; Aceito em: 12/05/2021; publicado em 01/08/2021. Copyright© Autor, 2021.

RESUMO: Métodos para classificação e identificação de atividades essenciais na análise das sementes é de grande importância técnica e econômica no setor agrícola e contribuem no valor acrescentado na produção final da cultura. Com a tecnologia no campo, demanda de solucionar diversos problemas, são inerentes a capacidade intelectual humana. O objetivo foi retratar desafios e as soluções evidentes no uso da inteligência artificial na agricultura e especificar a utilização desta atividade intelectual no setor sementeiro. Artigos revisados por pares sobre aprendizado de máquinas em sementes e inteligência artificial na agricultura foram relatados neste trabalho. O processamento de dados e imagens com uma visão de máquina se complementam através de um classificador em comum. Com a dinâmica de pesquisas atuais no ramo sementeiro, espera-se tendências que investigue em um futuro próximo, análise de dados característicos em sistemas de produção de sementes relacionado aos aspectos de beneficiamento, armazenamento, secagem e controle de qualidade.

PALAVRAS-CHAVE: Classificação de sementes, Futuro agrícola, Visão computacional.

ABSTRACT: Methods for classification and identification of essential activities in the analysis of seeds is of great technical and economic importance in the agricultural sector and contributes to the added value in the final production of the crop. With technology in the field, demand to solve several problems, human intellectual capacity is inherent. The objective was to portray challenges and evident solutions in the use of artificial intelligence in agriculture and to specify the use of this intellectual activity in the seed sector. Peer-reviewed articles on seed machine learning and artificial intelligence in agriculture were reported in this paper. The processing of data and images with a machine vision are complemented through a common classifier. With the dynamics of current research in the seed industry, trends are expected to investigate in the near future, analysis of characteristic data in seed production systems related to the aspects of processing, storage, drying and quality control.

KEYWORDS: Seed classification, Agricultural future, Computer vision.

INTRODUÇÃO

A inteligência artificial (IA) tem chamado atenção em todos os ramos de estudos e na agricultura não é diferente. Cada setor agrícola está conquistando espaço para atuação em todo o processo de produção. O aprendizado das máquinas tem impactado todos os setores da economia, especialmente pela capacidade de análise e de interpretação de dados em velocidade superior à do ser humano, de tal forma que os investimentos e as adesões em IA são crescentes, especialmente para tornar os processos mais rápidos, desde fábricas, transportes, setor imobiliário e no agronegócio (MORETI et al., 2021).

A tecnologia chega ao campo e com ela surge a necessidade de obter respostas rápidas e eficientes, onde a capacidade intelectual humana não é capaz de suprir a rapidez da demanda de um volume alto de dados que precisam ser destinados corretamente na execução das atividades. Este aspecto envolve os setores sementeiros (semeadura, colheita, processamento, tratamento, armazenamento e testes de controle de qualidade), principalmente quando se tem uma demanda alta de análise, exemplo vários lotes de sementes para realizar avaliação do controle de qualidade e ao mesmo tempo destinar sua finalidade, seja para sementes ou grãos (comercialização). Estes lotes precisam passar por alguns testes de controle de qualidade (germinação, emergência, envelhecimento acelerado, condutividade elétrica, teste frio, teor de água e etc) no qual vai garantir informações seguras sobre a qualidade das sementes.

E para interpretar todas as informações dos testes com uma demanda alta de análise dos lotes fica impossível a mente humana. As tecnologias baseadas em IA ajudam a melhorar a eficiência em todos os ramos de estudos e também a gerenciar os desafios enfrentados nas indústrias, incluindo os campos do setor agrícola, como o rendimento da safra, irrigação, detecção de conteúdo do solo, monitoramento de safra, capina e estabelecimento da cultura (KIM et al., 2008). De acordo com Talaviya et al. (2020), as soluções tecnológicas baseadas em IA permitiram que os agricultores produzissem mais com menos insumos e até melhoraram a qualidade da produção, garantindo também um lançamento mais rápido das safras no mercado.

A inteligência artificial permite aos agricultores e produtores reunir quantidade elevada de dados, analisá-los todos e fornecer aos agricultores soluções para muitos problemas ambíguos, além de fornecer uma maneira mais inteligente na tomada de decisão rápida e eficiente, resultando em melhor custo-benefício para os agricultores

(PANPATTE, 2018). O setor agrícola depende de ideias inovadoras e avanços tecnológicos para ajudar a aumentar a produtividade e alocar melhor os recursos (SINGH et al., 2021).

Então, o objetivo com este artigo consiste em retratar os desafios e as soluções mais evidentes no uso da IA na agricultura e especificar as formas de utilização desta atividade intelectual no setor sementeiro.

METODOLOGIA

Usou-se uma metodologia dedutiva, de caráter exploratório, fundamentada em pesquisa bibliográfica. Este trabalho revisa pesquisas anteriores e atuais sobre o uso e a aplicação de inteligência artificial na agricultura acompanhado de seus efeitos no setor sementeiro, mostrando em qual seguimento existe estudos dentro da ciência de sementes. Poucos estudos foram encontrados abordando sobre ensaios diretamente ligados aos tipos de aprendizado de máquinas e sua evolução na cadeia sementeira. Neste contexto, foi feita uma abordagem com maior enfoque na influência da inteligência artificial no uso da agricultura geral e seus efeitos sobre os algoritmos testados para classificar componentes agrícolas. E também foram destacados alguns trabalhos que retratam algoritmos utilizados na área sementeira.

As palavras-chave utilizadas na coleta de literatura para esta revisão foram “aprendizado de máquinas em sementes”, “inteligência artificial na agricultura”, “inteligência artificial em sementes”, “algoritmos estatísticos”, “máquinas do futuro na agricultura”, “agricultura do futuro” “modelos de algoritmos”, “árvore de decisão” e “redes neurais”. Bancos de dados computacional, agricultura de precisão e agricultura (todos os bancos de dados, CAB Abstracts e Global Health, Medline, Pubmed, Web of Science, BIOSIS Citation Index, Science Direct, Current Content Connect, Google Scholar, Scielo, Frontiers, e Springer Link) foram pesquisados entre fevereiro e março de 2021.

Especificamente, aprendizado de máquinas em sementes e inteligência artificial na agricultura relataram trabalhos empregados nos últimos 22 anos (1999–2021), como suas técnicas de modelagem e seus domínios de pesquisa para solucionar os mais variados problemas encontrados, foram considerados prioritários. Os artigos com abrangência sobre métodos de uso e aprendizado de máquinas aplicado a inteligência

artificial no setor sementeiro foram prioritários, o estado em que os experimentos foram realizados, o tipo de ensaio utilizado, a modelagem testada e a forma de como a técnica computacional de aplicação mostrava a eficiência do aprendizado das máquinas, foram considerados na filtração.

O Science Direct foi filtrado usando 'pesquisa Science direct' (inteligência artificial na agricultura com enfoque em sementes) e (aprendizado de máquinas em sementes) - em vista dos retornos de títulos >25 - e outros filtros foram aplicados a outras bases de dados conforme necessário. Todos os documentos considerados estavam em inglês e foram traduzidos para o português.

REFERENCIAL TEÓRICO

Na literatura para inteligência artificial aplicado no setor de sementes, ainda existe uma abordagem superficial quanto ao aprendizado de máquinas em vários segmentos da área sementeira. No presente trabalho, apresentamos pesquisas atuais que estão sendo desenvolvidas neste setor, que possibilitam a aplicabilidade nos mais diversos tipos de dados de um campo de produção agrícola (sementeiro). A literatura tem abordado técnicas de visão computacional e imagem multiespectral para classificação de danos, viabilidade, fenotipagem, espécies de fungos, teste de pureza física, previsão de germinação, produção e predição de ranqueamento de lotes em sementes. Este último, ainda são necessários maiores aprimoramento para detectar a validação eficaz de um tanto de variáveis que surge na pós-colheita, uma vez, validado pode minimizar custos no controle de qualidade de sementes para os laboratórios.

E também são apresentados diversos modelos de técnicas para aprendizado de máquinas de acordo com a necessidade de modelagem dos dados. Essa abordagem com imagem em sementes envolve aspectos fenotípicos como seus parâmetros de refletância, cor, tamanho e textura correspondentes. Os algoritmos de aprendizagem mais utilizados na inteligência artificial nesse setor agrícola é o de rede neural e árvore de decisão. Sendo que o primeiro, tem chamado mais atenção dos pesquisadores em obter respostas por meio de classificação por multicamadas, no qual, ele trabalha os dados brutos escondidos agrupando-os e classificando-os e simula conexões de um cérebro humano.

INTELIGÊNCIA ARTIFICIAL REVOLUÇÃO DO FUTURO NA AGRICULTURA

Com aumento da população mundial, a demanda por alimento também cresce impulsionado a tecnologia no desenvolvimento agrícola. Dados demonstrado pela FAO (2009, 2017), apontam que as pessoas precisariam aumentar a produção geral de alimentos em cerca de 70% entre 2005/07 e 2050. No entanto, os produtores agrícolas em todo o mundo precisarão aumentar a quantidade de terras agrícolas ou aumentando a produtividade em terras agricultáveis existentes pelo uso de agricultura de precisão ou inteligente (ELFERINK; SCHIERHORN, 2016).

As tecnologias agrícolas atuais são geralmente desviadas para algoritmos de aprendizado de máquinas porque maximizam o rendimento da colheita com a minimização dos custos de insumos (REHMAN et al., 2019). O algoritmo de aprendizado de máquinas permite que o agricultor aprimore a seleção de plantio, previsão de safra, de rendimento, de doenças, do clima, preço mínimo de suporte e sistema de irrigação inteligente (KAUR, 2016). Como também colheita e seleção de lotes de sementes.

O uso de inteligência artificial envolve o processo de aprendizagem das máquinas. De acordo Jha et al. (2019), o único propósito do aprendizado de máquinas é alimentar um sistema de dados com experiências anteriores e dados estatísticos para que ela possa executar sua tarefa atribuída para resolver um problema específico. O aprendizado de máquinas é uma abordagem matemática para construir máquinas inteligentes.

IA é uma tecnologia emergente no campo da agricultura. Equipamentos e máquinas baseados em IA elevaram o sistema agrícola de hoje a um nível diferente (TALAVIYA et al., 2020). Dos padrões já visto na qualidade de produção agrícola. Esta tecnologia melhorou o desenvolvimento agrícola e melhorou o monitoramento, colheita, processamento e comercialização em tempo real (YANG et al., 2007).

As mais recentes tecnologias de sistemas automatizados que usam robôs, máquinas agrícolas e veículos aéreos não tripulados deram uma enorme contribuição no setor agroindustrial. Vários sistemas baseados em computador de alta tecnologia são projetados para determinar vários parâmetros importantes, como detecção de ervas daninhas, detecção de rendimento e qualidade da colheita e muitas outras técnicas (LIAKOS et al., 2018). E isso garante eficiência em todos os campos de atuação e/ou

setores dentro da agricultura e ajuda a gerenciar os desafios problemáticos enfrentados em um campo de produção e também nas indústrias.

As soluções tecnológicas baseadas em IA tem permitido que os agricultores aumentassem a produção com menos insumos e até melhoraram a qualidade da produção, garantindo lançamento mais rápido de produtos e/ou safras no mercado. Foi estimado que em 2020, os agricultores estariam usando 75 milhões de dispositivos conectados. Em 2050, espera-se que em média gere 4,1 milhões de pontos de dados todos os dias (TALAVIYA et al., 2020).

MODELOS DE TREINAMENTO PARA APRENDIZADO DE MÁQUINAS

O uso correto das técnicas de avaliação da seleção de modelo e de algoritmo é vital na pesquisa acadêmica de aprendizado de máquinas, bem como em muitos ambientes industriais (RASCHKA., 2018). A escolha correta de modelos ajuda a solucionar melhor o problema enfrentado. Portanto, a técnica de aprendizado de máquinas não são, e nunca serão, a solução para todos os problemas levantados pelos sistemas agrícolas. No entanto, essas técnicas fornecem um conjunto poderoso de ferramentas aplicada para diferentes campos de pesquisas (TAGARAKIS et al., 2013).

Técnicas de aprendizado de máquinas têm sido amplamente aplicadas na determinação da qualidade de produtos agrícolas e alimentícios (SAHA; MANICKAVASAGAN., 2021). Diferentes técnicas de aprendizado de máquinas como rede neural artificial (Artificial Neural Network - ANN), lógica Fuzzy (Fuzzy logic - FL), árvores de decisão, Naïve Bayes, agrupamento de k-means, máquinas de vetor de suporte (support vector machines - SVM), floresta aleatória (Random forest - RF), (REHMAN et al., 2019).

Também se destacam regressão linear múltipla (multiple linear regression - MLR) multicamadas perceptron (multi-layer perceptron - MLP), São a as mais utilizadas para aprendizado profundo de máquinas na área agrícola. Recentemente técnicas de modelagem não linear e dinâmica, têm sido empregadas para o desenvolvimento de modelos precisos em ciências ambientais (JAHANI., 2019a; 2019b; MOSAFFAEI et al., 2020).

Uma técnica destes modelos quando não treinados adequadamente, não apresenta consistência na validação dos dados apresentados, por isso, deve ser sempre coerente na

aplicabilidade de cada treinamento para o aprendizado das máquinas. Em determinada situação Zhou et al. (2019), afirma que o aprendizado profundo é outro subdomínio do aprendizado de máquinas que pode demonstrar desempenho superior na classificação de dados em diferentes produtos e estabelecer seu potencial para superar até mesmo humanos em alguns casos, quando treinados adequadamente.

A aprendizagem tem dois tipos principais: supervisionada e não supervisionada. No aprendizado supervisionado, os dados de treinamento têm rótulos de saída, mas no aprendizado não supervisionado, os dados não têm rótulos de saída (CINAR, 2020). A rede neural artificial é uma das mais testadas nos mais diversos campos de aplicação, e na agricultura não é diferente.

INTELIGÊNCIA ARTIFICIAL NO SETOR DE SEMENTES E USO DE IMAGENS ESPECTRAIS

A IA é aplicada por meio do gerenciamento informações e dados de uma cultura (visão computacional, aprendizado de máquinas, reconhecimento de padrões, robótica), a automação das operações agrícolas (PANT, 2016). E isso permite visualizar que a inteligência artificial é qualquer tecnologia que substituir o trabalho do homem, com maior eficácia.

Atualmente, a determinação da qualidade de sementes é feita manualmente por especialistas com testes de controle de qualidade ou em classificadores de grãos antes da fase de comercialização. Varela et al. (2020), verificaram através de ferramenta de software web que permite determinar o nível de qualidade de uma amostra de milho automaticamente a partir de uma imagem. Algoritmos de processamento de imagens foram implementados para corrigir distorções causadas principalmente pelo processo de captura. Foi utilizado o algoritmo de classificação K-Means.

Modelar as relações entre rendimento de sementes e seus componentes físicos (pureza, teor de umidade, tamanho, cor, densidade, danos mecânicos e causados por insetos), fisiológicos (vigor, germinação: está relacionado a capacidade de desempenhar funções vitais), sanitário (doenças, patógenos e fungos) e genético (pureza varietal, homogeneidade, potencial de rendimento, resistência a doenças e insetos, precocidade, estatura, estrutura de plantas), será útil para entender as características mais importantes com efeitos significativos na qualidade e produção de sementes.

Sobre esse aspecto citado acima, em estudo com sementes de Cártamo, Moslem et al. (2019), modelaram a produção de sementes através de redes neurais artificiais e regressão linear múltipla, onde avaliaram através de cinco modelos de redes neurais com diferentes algoritmos de aprendizagem funções de transferência, camadas ocultas e neurônios em cada camada, junto com modelo de regressão multilinear para prever a produção de sementes de Cártamo. E também foi estudado por Saffariha et al. (2020), a previsão de germinação de sementes de *Salvia limbata* sob estresse. Onde, analisaram a germinação de sementes sob quatro estresses ecológicos: salinidade, seca, temperatura e pH, com aplicação de técnicas de modelagem de inteligência artificial, MLR e MLP.

A pureza das sementes é o fator mais importante na agricultura que determina o rendimento, a qualidade das sementes, o preço e a qualidade da safra. Arroz basmati na Índia apresentam diversas variedades e pesquisadores tem os desafios de selecionar a melhor variedade de alto rendimento e para isso, eles desenvolveram um servidor Web baseado na predição através de inteligência artificial que possa identificar as principais variedades de arroz basmati. Sendo baseado em imagens de sementes, para a identificação e diferenciação de dez variedades principais de arroz (SHARMA et al., 2020).

Os avanços nas técnicas de inteligência artificial vêm permitindo a combinação de métodos de análise de imagens e aprendizado de máquinas para diversos fins. Um estudo recente mostra a possibilidade de classificação das sementes de *Jatropha curcas* L. quanto à sua qualidade por meio do uso de dados fenotípicos obtidos por análise de imagens de raios-X com abordagens de aprendizado de máquinas (MEDEIROS et al., 2020a). Mahajan et al. (2018), avaliaram adequações de técnicas de imagem do tipo não-destrutiva e sem contato, como imagem visível e por raio-X, em testes de pureza física, viabilidade e vigor de sementes de soja. E Monteiro et al. (2021), investigaram danos e tons de cores em sementes (esverdeadas) de soja via processamento de imagens.

Um estudo com radiografia de sementes de espécies agrícolas foi investigada por Medeiros et al., 2020b, através de uma ferramenta chamada IJCropSeed. Foi desenvolvida na linguagem macro do software ImageJ® (SHNEIDER et al., 2012). E nesta ferramenta foi inserido 24 culturas agrícolas que podem ser analisadas por radiografias, sendo: Repolho (*Brassica oleracea* var. capitata L.), Couve-flor (*Brassica oleracea* var. botrytis L.), Chicória (*Cichorium intybus* L.), Café (*Coffea* sp. L.), Feijão-caupi (*Vigna unguiculata* (L.) Walp.), Crambe (*Crambe abyssinica* Hochst. ex REFr.), Crotalaria (*Crotalaria juncea* L.), Lentilha (*Lens culinaris* Medik.), Milho (*Zea mays* L.), Melão (*Cucumis melo* L.), Feijão mungo (*Vigna radiata* (L.) R.Wilczek), Quiabo (*Abelmoschus*

esculentus Moench), Cebola (*Allium cepa* L.), Grama Panicum (*Panicum maximum* Jacq), Mamão (*Carica papaya* L.), Ervilha (*Pisum sativum* L.), Pimenta (*Capsicum chinense* Jacq.), Sorgo (*sorghum bicolor* (L.) Moench), Soja (*Glycine max* (L.) Merr.), Girassol (*Helianthus annuus* L.), Milho doce (*Zea mays* L.), Tomate (*Solanum lycopersicum* L.), Grama urochloa (*Urochloa brizantha* (A.Rich.) RDWebster) e Trigo (*Triticum* L.). Sementes de Crambe foram utilizadas para desenvolver modelos de aprendizado de máquinas (MEDEIROS et al., 2020b).

A aplicação de ultrassom em sementes com modelagem de IA também é alvo de investigação. Wen et al. (2012), observaram o efeito do ultrassom sobre o rendimento de fenólicos totais e a atividade antioxidante da semente de *Dimocarpus longan* Lour. Onde uma rede neural multicamadas feed-forward treinada com um algoritmo de retropropagação de erro foi empregada para construir um modelo matemático.

Como na inspeção ocular, a classificação automática das sementes deve ser baseada no conhecimento do tamanho, forma, cor e textura da semente, esses podem ser critérios usados para identificar sementes de planta daninhas através de um classificador Naïve Bayes (GRANITTO et al., 2002). A aprendizagem por transferência é um método conveniente e eficiente para a adaptação do conhecimento (SALAKEN et al., 2018). A estratégia de aprendizagem por transferência foi aplicada para a detecção da autenticidade das sementes de milho, podendo até ser classificar suas características fenotípicas (tamanho, cor, forma e etc) e confirmar a autenticidade da variedade. Tu et al. (2021), estabeleceram que através de imagens RGB combinadas com aprendizado de máquinas ajuda a referenciar e identificar a autenticidade de sementes, por entrada de uma rede neural MLP. E isso pode ser aplicado a outras culturas.

Então, através de estudos de IA aliado com imagens multiespectrais podem ajudar na predição de determinados eventos que ocorre nas sementes em várias etapas de colheita e pós-colheita, por exemplo como danos (mecânico, por umidade, ataque de insetos) afetam os desempenhos das sementes. E para identificar esses tipos de lesão, principalmente o mecânico que é mais comum ocorrer durante a colheita e no beneficiamento é algo demorado e precisa de pessoal treinados. Então, Salimi e Boelt (2019), investigaram através de imagem multiespectral diferentes tipos de danos em sementes de cenoura, no qual modelos de classificação foram utilizados. ElMasry et al. (2019), se basearam em análise multivariadas e imagem espectrais para classificar as sementes de feijão-caupi (*Vigna unguiculata*) em diferentes categorias de acordo com o envelhecimento, viabilidade, condição de plântulas a e velocidade de germinação.

Os métodos convencionais de detecção de fungos transmitidos por sementes são trabalhosos e demorados, exigindo analistas especializados para a caracterização de fungos patogênicos nas sementes. Imagem multiespectral combinada com visão de máquina foi usada como um método alternativo para detectar *Drechslera avenae* (Eidam) Sharif [*Helminthosporium avenae* (Eidam)] em sementes de aveia preta (*Avena strigosa* Schreb) (FRANÇA-SILVA et al., 2020). Neste caso, foi determinado um modelo de classificação com base na análise discriminante linear e através de comprimentos de onda dentro da faixa espectral de 365 a 970 nm. Olesen et al. (2015), também havia utilizado o mesmo comprimento de ondas em sementes de mamona (*Ricinus cummunis* L.), em testes de qualidade com uso de imagens multiespectrais.

INTELIGÊNCIA ARTIFICIAL NO MODO DE APLICAÇÃO E NA SELEÇÃO DE LOTES DE SEMENTES

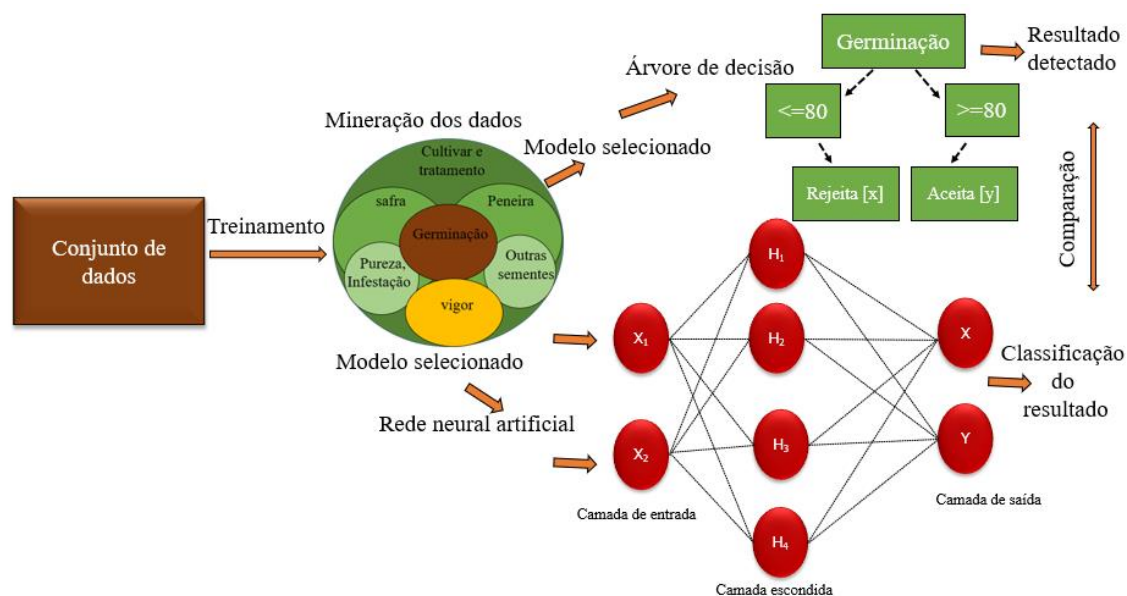
Atualmente grande empresas e laboratórios apresentam uma demanda de dados sobre cultivares ou culturas agrícolas que precisam ser tomadas as decisões corretas para comercialização, semeadura e colheita. No entanto, obter e repassar informações de uma infinidade de cultivares no mercado, requer cuidados e cautela. Pois uma demanda excessiva pode ocasionar erros de informações e levar sérios problemas a empresa.

Testes de controle de qualidade de sementes também são vários, alguns demorados e outro rápidos. Mas saber qual testes é mais adequado a ser realizado é um dos problemas enfrentados pelos laboratoristas, pois cada um complementa o outro. Portanto a regra é, quanto mais testes de qualidade melhor será para identificar um lote de qualidade fisiológica superior e assim, o aprendizado de máquinas ajuda com todos esses dados a ter uma rápida e eficiente decisão com tantas informações distintas. Com posse desses dados, através da inteligência artificial pode-se prever qual teste será necessário realizar primeiro ao determinar a qualidade da semente. Sem precisar incluir todos os testes, por exemplo o teste de vigor que complementa o de germinação, onde submete as sementes a diversos tipos de estresses (envelhecimento acelerado, teste de frio, deterioração controlada, teste tetrazólio) e avaliando as características das plântulas (crescimento de plântulas e fitomassa seca).

Com essa ferramenta facilitaria, nestes processos laborosos, na tomada de decisão. Na Figura 1 mostra um esboço de como o aprendizado de máquinas atuaria na

decisão rápida e eficiente para escolhas de lotes de maior qualidade fisiológica. A escolha do modelo testado fica melhor explicado pelos valores de acurácia. No qual ela demonstra o quanto o valor estimado é semelhante ao real.

Figura 1: O processo de segmentação e seleção da técnica de aprendizado de máquinas gerando uma árvore de decisão e rede neural em lotes de sementes.



Fonte: PINHEIRO, R. M (2021)

O conjunto de dados trabalhados em um treinamento de aprendizado de máquinas, geralmente são enormes, onde a análise humana pode ser prejudicada e delongada resposta. Quando são geradas informações de cultivar, tratamentos, safra, peneira, pureza, percentual de infestação, percentual de outras sementes, germinação e vigor, torna-se um trabalho lento e de pouca eficiência para a tomada de decisão. Então, testar os modelos classificadores são essenciais para corresponder o desempenho do algoritmo sobre o conjunto de dados fornecido.

Em uma árvore de decisão os atributos testados como classificadores e seletores de sementes expõe em qual situação pode aceitar ou rejeitar a qualidade das sementes sobre os atributos avaliados (mineração de dados), o algoritmo escolhe o atributo por meio do ganho de informação da quantidade de maiores valores encontrados no conjunto de dados, ou seja, o quanto informativo um atributo é (VIEIRA, 2018). Quanto a rede neural, apresenta camadas de entrada e de saída. As redes neurais simulam as conexões no cérebro humano (HAYKIN, 1999). Basicamente, a rede neural artificial pega as

entradas, as calcula e produz as saídas. Este processo é conhecido como aprendizagem (CINAR et al., 2020). Em estudo com predição de ranqueamento de lotes de sementes de milho por inteligência artificial, Moraes (2020), definiu os algoritmos testados através de critérios de valores apresentados nas acurácias e matriz de confusão.

Importante ressaltar, que ao analisar os valores de acurácia em fase inicial de treinamento dos dados, quando se obtêm valores alto de porcentagem, implica no grau de aprendizado das máquinas e prediz o quanto aquela informação ainda precisa ser trabalhada. Por exemplo, quando é observado um valor de 98% de acurácia, ela pode implicar que a máquina não aprendeu quase nada nos dados trabalhados. Ou seja, quando a acurácia apresenta alto valores, ainda necessita treinar mais a máquina, isso é relacionado ao comportamento de matriz de confusão onde ela ainda não consegue diferenciar as informações e assim, sendo necessário distinguir o que aceita e o que rejeita ou conforme designe a resposta.

Outro segmento ligado a sementes que necessitam de modernização digital e tecnológica são os laboratórios, onde, equipamentos em laboratório são regulados conforme normativas de cada órgão fiscalizador, são necessários calibrações uniforme e padronização em todos os laboratórios, que emitam atestados da qualidade de sementes. Esses atestados são imprescindíveis para a comercialização, armazenamento, distribuição de sementes. O teste de sementes também é usado na pesquisa e na identificação de problemas de qualidade (TILLMANN; MENEZES, 2012). Souza et al. (2019), apresentaram um sistema integrado composto por hardware, middleware e aplicativo para monitorar e registrar o desempenho de equipamentos nos testes de sementes, desde o início até a conclusão de cada teste em laboratórios de sementes (com o chamado internet das coisas). Portanto, o aprendizado de máquinas também pode ser útil para modernizar diversos equipamentos de laboratório. Isto associado a inteligência artificial torna imprescindível.

CONSIDERAÇÕES FINAIS

O avanço de Inteligência artificial com o aprendizado de máquinas tornará as tecnologias agrícolas precisas, eficientes, robustas e de baixo custo. O processamento de dados com uma visão de máquina se complementa através de imagem com um discriminador para classificar o alvo desejado com dados dimensionais elevados.

Estudos com processamento de imagem e aliado a aplicação de IA fornece resolução de problemas na ciência e tecnologia de sementes como métodos não destrutivos em suas análises. Técnicas de aprendizado de máquinas podem facilitar extração e seleção de recursos com algoritmos de previsão apropriado.

O campo das sementes ainda necessita ser explorado com maior robustez. Com a dinâmica de pesquisas atuais no ramo sementeiro, espera-se tendências que investigue em um futuro próximo, análise de dados característicos em sistemas de produção de sementes relacionado aos aspectos de beneficiamento, armazenamento, secagem e controle de qualidade.

REFERÊNCIAS

1. CINAR, A. C. Training feed-forward multi-layer perceptron neural network with a tree-seed algorithm. *Arabian Journal for Science and Engineering*. v. 45, p. 10915 - 10938, 2020. Doi: <https://doi.org/10.1007/S13369-020-04872-1>.
2. ELFERINK, M.; SCHIERHORN, F. *Global demand for food is rising. Can we meet it?* Harvard Business Review. 4p. April 07. 2016. <https://hbr.org/2016/04/global-demand-for-food-is-rising-can-we-meet-it>.
3. ELMASRY, G.; MANDOUR, N.; WAGNER, MH.; DEMILLY, D.; VERDIER, J.; BELIN, E., ROUSSEAU, D. Utilization of computer vision and multispectral imaging techniques for classification of cowpea (*Vigna unguiculata*) seeds. *Plant Methods*, v. 15, n. 24, 2019. Doi: <https://doi.org/10.1186/s13007-019-0411-2>.
4. FAO. Food and Agriculture Organization of the United Nations. *Global agriculture towards 2050: high-level expert forum on how to feed the world in 2050*, 12-13. Oct 2009 by Food and Agriculture Organization of the United Nations, 2009. <https://reliefweb.int/report/world/global-agriculture-towards-2050-high-level-expert-forum-how-feed-world-2050-12-13-oct>.
5. FAO. Food and Agriculture Organization of the United Nations, 2017. *The state of food and agriculture leveraging food systems for inclusive rural transformation*. 978-92-5-109873-8. 2017, p. 1-181.
6. FRANÇA-SILVA, F.; REGO, C. H. Q.; GOMES-JUNIOR, F. G.; MORAES, M. H. D.; MEDEIROS, A. D.; SILVA C. B. Detection of *Drechslera avenae* (Eidam) Sharif [*Helminthosporium avenae* (Eidam)] in Black Oat Seeds (*Avena strigosa* Schreb) using

multispectral imaging. *Sensors*, v. 20, n. 12, p. 33-43, 2020. doi: <https://doi.org/10.3390/s20123343>.

7. GRANITTO, P. M.; NAVONE, H. D.; VERDES, P. F.; CECCATTO, H. A. Weed seeds identification by machine vision, *Computers and Electronics in Agriculture*, v. 33, n. 2, p. 91-103, 2002. Doi: [https://doi.org/10.1016/S0168-1699\(02\)00004-2](https://doi.org/10.1016/S0168-1699(02)00004-2).
8. HAYKIN, S. *Neural networks: a comprehensive foundation*. New Jersey: Prentice Hall; Upper Saddle River, 1999. 218p.
9. JAHANI, A. Sycamore failure hazard classification model (SFHCM): an environmental decision support system (EDSS) in urban green spaces. *International Journal of Environmental Science and Technology*. v. 16, p. 955–964. 2019a Doi: <https://doi.org/10.1007/s13762-018-1665-3>.
10. JAHANI, A. Forest landscape aesthetic quality model (FLAQM): A comparative study on landscape modelling using regression analysis and artificial neural networks. *Journal of Forest Science*. v. 65, n. 2, 61–69, 2019b. Doi: <https://doi.org/10.17221/86/2018-JFS>.
11. JHA, K.; DOSHI, A.; PATEL, P.; SHAH, M. A comprehensive review on automation in agriculture using artificial intelligence, *Artificial Intelligence in Agriculture*, v. 2, p. 1-12, 2019. Doi: <https://doi.org/10.1016/j.aiia.2019.05.004>.
12. KAUR, K. Machine learning: applications in Indian agriculture. *International Journal of Advanced Research in Computer and Communication Engineering*, v. 5, n. 4. 2016.
13. KIM, R. G.; EVANS; W. M. IVERSEN. Remote sensing and control of an irrigation system using a distributed wireless sensor network. *IEEE Transactions on Instrumentation and Measurement*, v. 57, n. 7, p. 1379-1387, 2008. Doi: 10.1109/TIM.2008.917198.
14. LIAKOS, K.; BUSATO, P.; MOSHOV, D.; PEARSON, S.; BOCHTIS, D. Machine learning in agriculture: A review. *Sensors*, v. 18, n. 8, p. 2674, 2018. Doi: 10.3390/s18082674.
15. MAHAJAN, S.; MITTAL, S. K; DAS, A. Alternative test approach based on machine vision for testing physical purity, viability and vigor of soybean seeds (*Glycine max*). *Journal of Food Science and Technology*, v. 55, n. 10, p. 3949-3959. Doi: <https://doi.org/10.1007/s13197-018-3320-x>
16. MEDEIROS, A. D. de; PINHEIRO, D. T.; XAVIER, W. A.; SILVA, L. J. da; DIAS, D. C. F. dos S. Quality classification of *Jatropha curcas* seeds using radiographic

images and machine learning. *Industrial Crops and Products*, v. 146, p. 112-162, 2020a.

Doi: <https://doi.org/10.1016/j.indcrop.2020.112162>.

17. MEDEIROS, A. D. de; SILVA, L. J.; SILVA, J. M.; DIAS, D. C. F. S.; PEREIRA, M. D. IJCropSeed: An open-access tool for high-throughput analysis of crop seed

radiographs. *Computers and Electronics in Agriculture*, v. 175, p. 105555, 2020b. Doi: <https://doi.org/10.1016/j.compag.2020.105555>.

18. MONTEIRO, R. C. M.; GADOTTI, G. I.; MALDANER, V.; CURTI, A. B. J.; BARBARA NETO, M. Image processing to identify damage to soybean seeds. *Ciência Rural*, v. 51, p. 1-8, 2021. Doi: <https://doi.org/10.1590/0103-8478cr20200107>.

19. MORAES, N. A. B. *Predição de ranqueamento de lotes de sementes de milho por inteligência artificial*. 2020, 29 f. Dissertação de Mestrado em Ciências – Programa de Pós-Graduação em Ciência e Tecnologia de Sementes. Universidade Federal de Pelotas, Pelotas/RS. 2020. link: <http://guaiaca.ufpel.edu.br/handle/prefix/5713>.

20. MORETI, M. P.; OLIVEIRA, T.; SARTORI, R.; CAETANO, W. Inteligência artificial no agronegócio e os desafios para a proteção da propriedade intelectual.

Cadernos de Prospecção, v. 14, p. 60, 2021. Doi:

<http://dx.doi.org/10.9771/cp.v14i1.33098>.

21. MOSAFFAEI, Z.; JAHANI, A.; ZARE, C. M. A.; GOSHTASB, H.; ETEMAD, V. SAFFARIHA, M. Soil texture and plant degradation predictive model (STPDPM) in national parks using artificial neural network (ANN). *Journal Modeling Earth Systems and Environment*, v. 6, p. 715–29, 2020. Doi: <https://doi.org/10.1007/s40808-020-00723-y>.

22. MOSLEM, A.; YOUNESSI-HMAZEKHANLU, M.; RAMAZANI, S. H. R.; OMIDI, A. H. Artificial neural networks and multiple linear regression as potential methods for modeling seed yield of safflower (*Carthamus tinctorius* L.), *Industrial Crops and Products*, v. 127, p. 185-194, 2019. Doi:

<https://doi.org/10.1016/j.indcrop.2018.10.050>.

23. OLESEN, M. H.; NIKNESHAN, P.; SHRESTHA, S.; TADAYYON, A.; DELEURAN, L. C.; BOELT, B.; GISLUM, R. Viability prediction of *Ricinus communis* L. seeds using multispectral imaging. *Sensors*, v. 15 n. 2, p. 4592-4604, 2015. Doi:

<https://doi.org/10.3390/s150204592>

24. PANPATTE, D. G. *Artificial intelligence in agriculture: an emerging era of research*. Anand Agricultural University, Canada, p. 1-8, 2018.

25. PANT, L. P. Digitally engaged rural community development. *Journal of Agriculture, Food Systems, and Community Development*, v. 6, n. 4, p. 169-171, 2016. Doi: 10.5304/jaf.scd.2016.064.005.
26. RASCHKA, S. Model evaluation, model selection, and algorithm selection in machine learning. *arXiv*, v. 3, p. 1-48, 2018. Doi: arXiv:1811.12808.
27. REHMAN, T. U.; SULTAN MAHMUD, M. D.; CHANG, Y. K.; JIN, J.; SHIN, J. Current and future applications of statistical machine learning algorithms for agricultural machine vision systems, *Computers and Electronics in Agriculture*, v. 156, p. 585-605. 2019. Doi: <https://doi.org/10.1016/j.compag.2018.12.006>.
28. SAFFARIHA, M.; JAHANI, A.; POTTER, D. Germination prediction of *Salvia limbata* seeds under ecological stress in protected areas: an artificial intelligence modeling approach. *BMC Ecology*, v. 20, 48, 2020. Doi: <https://doi.org/10.1186/s12898-020-00316-4>.
29. SAHA, D.; MANICKAVASAGAN, A. Machine learning techniques for analysis of hyperspectral images to determine quality of food products: A review, *Current Research in Food Science*, v. 4, p. 28-44, 2021. Doi: <https://doi.org/10.1016/j.crf.2021.01.002>.
30. SALAKEN, M. S.; ABBAS, K.; THANH, N.; SAEID, N. Seeded transfer learning for regression problems with deep learning. *Expert Systems with Applications*, v. 115, p. 565-577. 2018. Doi: <https://doi.org/10.1016/j.eswa.2018.08.041>.
31. SALIMI, Z.; BOELT, B. Classification of processing damage in sugar beet (*Beta vulgaris*) seeds by multispectral image analysis. *Sensors*, v. 19, n. 10, p. 23-60, 2019. Doi: <https://doi.org/10.3390/s19102360>.
32. SCHNEIDER, C. A.; RASBAND, W. S.; ELICEIRI, K. W. NIH Image to ImageJ: 25 years of image analysis. *Nature Methods*, v. 9, p. 671-675, 2012. Doi: 10.1038/nmeth.2089.
33. SHARMA, A. SATISH, D.; SHARMA, S.; GUPTA, D. iRSVPred: A web server for artificial intelligence based prediction of major basmati paddy seed varieties. *Frontiers in Plant Science*, v. 10, p. 1791, 2020. Doi: 10.3389/fpls.2019.01791.
34. SINGH, G.; SINGH, A.; KAUR, G. *Role of artificial intelligence and the internet of things in agriculture*. 16. Ed(s): KAUR, G.; TOMAR, P.; TANQUE, M. Artificial intelligence to solve pervasive internet of things issues, Academic Press, c. 16, p. 317-330, 2021. Doi: <https://doi.org/10.1016/B978-0-12-818576-6.00016-1>.

35. SOUZA, S. de R.; LOPES, B.; LADISLAU, J.; RESIN GEYER, C. F.; DA ROSA, S. J. L.; AFONSO CARDOZO, A.; CORRÊA, Y. A.; GADOTTI, G. I.; BARBOSA, J. L. V. Continuous monitoring seed testing equipments using internet of things. *Computers and Electronics in Agriculture*, v. 158, p. 122-132, 2019. Doi: <https://doi.org/10.1016/j.compag.2019.01.024>.
36. TAGARAKIS, A.; LIAKOS, V.; FOUNTAS, S.; KOUNDOURAS, S.; GEMTOS, T. Management zones delineation using fuzzy clustering techniques in grapevines. *Precision Agriculture*, v. 14, n. 1, p. 18-39, 2013. Doi: <https://doi.org/10.1007/s11119-012-9275-4>.
37. TALAVIYA, T.; SHAH, D.; PATEL, N.; YAGNIK, H.; SHAH, M. Implementation of artificial intelligence in agriculture for optimisation of irrigation and application of pesticides and herbicides. *Artificial Intelligence in Agriculture*, v. 4, p. 58-73, 2020. Doi: <https://doi.org/10.1016/j.aiia.2020.04.002>.
38. TILLMANN, M. A. A.; MENEZES, N. L. *Análise de Sementes. In: Sementes: Fundamentos científicos e tecnológicos*. Ed. Universitária/UFPel, Pelotas, p. 138-198, c. 3, 2012.
39. TU, K.; WEN, S.; HENG, Y.; ZHANG, T.; PAN, T.; WANG, J.; WANG, J.; SUN, Q. A non-destructive and highly efficient model for detecting the genuineness of maize variety 'JINGKE 968' using machine vision combined with deep learning. *Computers and Electronics in Agriculture*, v. 182, p. 106002, 2021. Doi: <https://doi.org/10.1016/j.compag.2021.106002>.
40. VARELA, N.; SILVA, J.; PINEDA, O. B.; CABRERA, D. Prediction of the corn grains yield through artificial intelligence. *Procedia Computer Science*, v. 170, p. 1017-1022, 2020. Doi: <https://doi.org/10.1016/j.procs.2020.03.080>.
41. VIEIRA, E. M. de A.; NEVES, N. T. de A. T.; de OLIVEIRA, A. C. C.; de MORAES, R. M.; do NASCIMENTO, J. A. Avaliação da performance do algoritmo J48 para construção de modelos baseados em árvores de decisão. *Revista Brasileira de Computação Aplicada*, v. 10, p. 80-90, 2018. Doi: <https://doi.org/10.5335/rbca.v10i2.8078>.
42. ZHOU, L.; ZHANG, C.; LIU, F.; QIU, Z.; HE, Y. Application of deep learning in food: a review. *Comprehensive Reviews in Food Science and Food Safety*, v. 18, p. 1793-1811, 2019. Doi: <https://doi.org/10.1111/1541-4337.12492>.

43. YANG, H.; LIUSHENG, W.; HONGLI JUNMIN, X. *Wireless Sensor Networks for Intensive Irrigated Agriculture, Consumer Communications and Networking Conference, 2007. CCNC 2007. 4th IEEE*, p. 197-201. Las Vegas, Nevada. Jan. 2007.

44. WEN, L.; YANG, B.; CUI, C.; YOU, L.; ZHAO, M. Ultrasound-assisted extraction of phenolics from Longan fruit seeds (*Dimocarpus longan* Lour.) With artificial neural network and its antioxidant activity. *Food Analytical Methods*, v. 5, p. 1244-1251, 2012. Doi: <https://doi.org/10.1007/s12161-012-9370-1>.