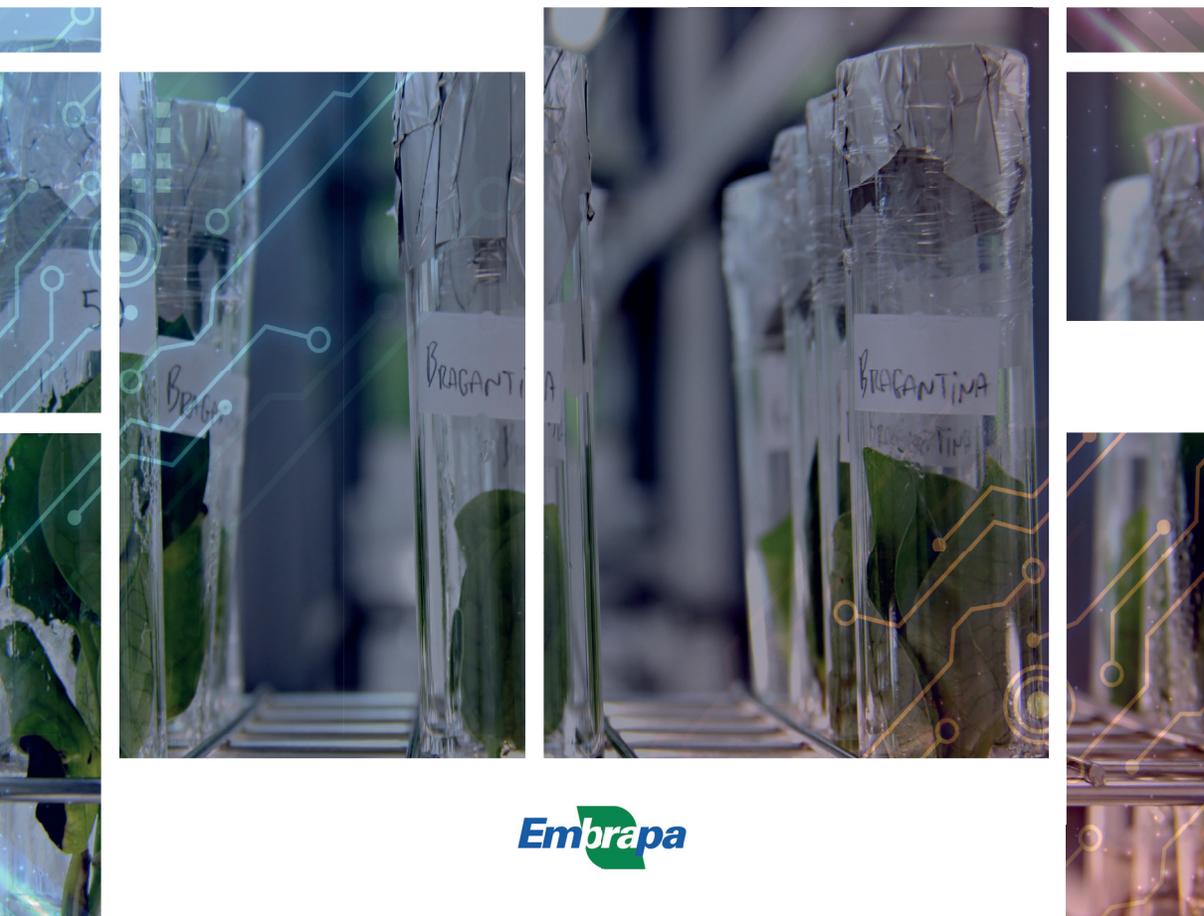


Fluxo de Trabalho para o Treinamento de Modelos de Aprendizado Profundo Dedicados a Problemas da Agricultura



***Empresa Brasileira de Pesquisa Agropecuária
Embrapa Agricultura Digital
Ministério da Agricultura, Pecuária e Abastecimento***

**BOLETIM DE PESQUISA
E DESENVOLVIMENTO
51**

Fluxo de trabalho para o treinamento
de modelos de aprendizado profundo
dedicados a problemas da agricultura

Jayme Garcia Arnal Barbedo

***Embrapa Agricultura Digital
Campinas, SP
2021***

Embrapa Agricultura Digital

Av. Dr. André Tosello, 209 - Cidade Universitária
Campinas, SP, Brasil
CEP. 13083-886
Fone: (19) 3211-5700
www.embrapa.br
www.embrapa.br/fale-conosco/sac

Comitê Local de Publicações
Presidente
Stanley Robson de Medeiros Oliveira

Secretária-Executiva
Maria Fernanda Moura

Membros
Adriana Farah Gonzalez, membro nato, Alexandre de Castro, membro indicado, Carla Cristiane Osawa, membro nato, Debora Pignatari Drucker, membro eleito, Ivan Mazoni, membro eleito, João Camargo Neto, membro indicado, Joao Francisco Goncalves Antunes, membro eleito, Magda Cruciol, membro nato.

Supervisão editorial
Stanley Robson de Medeiros Oliveira

Revisão de texto
Adriana Farah Gonzalez

Normalização bibliográfica
Carla Cristiane Osawa

Projeto gráfico da coleção
Carlos Eduardo Felice Barbeiro

Editoração eletrônica
Mariana Pilatti sob supervisão de Magda Cruciol

Foto da capa
Ronaldo Rosa e Freepik adaptado por Mariana Pilatti

1ª edição
Publicação digital - PDF (2021)

Todos os direitos reservados.

A reprodução não autorizada desta publicação, no todo ou em parte, constitui violação dos direitos autorais (Lei nº 9.610).

Dados Internacionais de Catalogação na Publicação (CIP)
Embrapa Agricultura Digital

Barbedo, Jayme Garcia Arnal.

Fluxo de trabalho para o treinamento de modelos de aprendizado profundo dedicados a problemas da agricultura / Jayme Garcia Arnal Barbedo. - Campinas: Embrapa Agricultura Digital, 2021.

PDF (17 p.) : il. color. - (Boletim de pesquisa e desenvolvimento / Embrapa Agricultura Digital, ISSN 2764-2623 ; 51).

1. Redes neurais. 2. Aprendizado profundo. 3. Deep learning. I. Barbedo, Jayme Garcia Arnal. II. Título. III. Embrapa Agricultura Digital. IV. Série.

CDD (21. ed.) 006.32

Carla Cristiane Osawa (CRB-8/10421)

© Embrapa, 2021

Sumário

Introdução.....	7
Captura de Imagens	7
Anotações das Imagens.....	10
Planejamento dos Experimentos.....	10
Seleção de Modelos.....	12
Conclusão.....	13
Referências.....	13

Fluxo de Trabalho para o Treinamento de Modelos de Aprendizado Profundo Dedicados a Problemas da Agricultura

Jayme Garcia Amal Barbedo¹

Resumo – Com o surgimento do aprendizado profundo, redes neurais novamente se tornaram opções vantajosas para lidar com uma variedade de problemas de classificação, especialmente quando imagens digitais estão envolvidas. A popularização desse tipo de técnica deu origem a uma comunidade ativa que tornou pública a maior parte das arquiteturas de aprendizado profundo desenvolvidas até o momento. Documentações completas e tutoriais detalhados associados a essas arquiteturas garantem que qualquer pessoa com conhecimentos básicos de programação é capaz de realizar os experimentos sem muito esforço. Como resultado, houve uma explosão no número de artigos aplicando aprendizado profundo a uma ampla gama de problemas. Apesar dos excelentes resultados alcançados por técnicas de aprendizado profundo, modelos de aprendizado profundo ainda são frequentemente aplicados sem as precauções necessárias para evitar resultados irrealistas ou enviesados. Há muitas sutilezas que raramente são mencionadas nos materiais de referência associados aos modelos de aprendizado profundo, sendo frequentemente ignorados quando os experimentos são idealizados. A natureza “caixa preta” dos modelos de aprendizado profundo agrava este cenário, porque potenciais problemas com o ajuste do modelo não são facilmente detectados. O objetivo deste trabalho é detalhar cada passo do fluxo de trabalho normalmente adotado para treinar modelos de aprendizado profundo, com especial atenção dedicada às muitas armadilhas que podem tornar os modelos gerados inadequados para uso prático.

Termos para indexação: aprendizado profundo, treinamento, redes neurais, classificação.

¹Engenheiro Eletricista, doutor em Engenharia Elétrica, pesquisador da Embrapa Agricultura Digital, Campinas, SP.

Workflow for Training Deep Learning Models Dedicated to Agricultural Problems

Abstract – With the rise of deep learning, neural networks once again became prime options to tackle a variety of classification problems, especially when digital images are involved. The popularization of this type of technique gave rise to an active community that has made publicly available most of the deep learning architectures developed so far. Comprehensive documentation and detailed tutorials associated to those architectures ensure that anyone with only basic programming knowledge can carry out experiments almost effortlessly. As a result, there has been an explosion of articles applying deep learning to a wide variety of problems. Despite the remarkable results that are being achieved by deep learning techniques, deep learning models are often applied without the necessary precautions to avoid unrealistic or biased results. There are many subtleties which are rarely mentioned in basic reference material associated to deep learning models, thus being frequently ignored when experiments are designed. The “black box” nature of deep learning models aggravates this issue, because potential problems with the model fitting cannot be easily detected. The objective of this work is to detail each step of the workflow normally adopted for training deep learning models, with special attention being dedicated to the numerous pitfalls that may render the generated models useless for practical use.

Index terms: deep learning, training, neural networks, classification.

Introdução

Inteligência artificial, e aprendizado profundo em particular, vêm sendo cada vez mais aplicados a problemas agrícolas devido à sua habilidade de lidar com as características não-estruturadas e dinâmicas encontradas no campo. Métodos de classificação baseados em modelos de aprendizado profundo normalmente empregam Redes Neurais Convolucionais (Convolutional Neural Networks - CNN) (Krizhevsky et al., 2012; Szegedy et al., 2015; Chollet, 2017; Zoph et al., 2018). O problema de classificação é o mais explorado na literatura, cujos artigos estão dentre os mais citados na literatura (Mohanty et al., 2016; Brahimi et al., 2017; Johannes, 2017; Lu et al., 2017; Ramcharan et al., 2017; Ferentinos, 2018; Liu et al., 2018; Zhang et al., 2018; Barbedo, 2019; Jiang et al., 2019; Too et al., 2019; Argüeso et al., 2020; Chen et al., 2020; Darwish et al., 2020; Lee et al., 2020; L; Rahman et al., 2020; Zhong, Zhao, 2020). Problemas de detecção são frequentemente tratados como um problema de classificação binário, no qual a primeira classe é o objeto de interesse (sintoma de doença, fruta, animal, inseto, etc.), e a segunda classe é todo o restante (Barbedo, 2013, 2021). Embora arquiteturas voltadas exclusivamente à classificação possam ser aplicadas nesse caso, modelos de detecção como o YOLOv3 (Redmon; Farhadi, 2018) e o Mask R-CNN (He et al., 2017) são frequentemente preferidos, uma vez que estes podem não apenas detectar a presença do objeto de interesse, mas também indicar onde os sintomas estão localizados. Problemas de segmentação normalmente empregam modelos de segmentação semântica tais como Deeplab v3 (Chen et al., 2017), SegNet (Badrinarayanan et al., 2016), e U-Net (Ronneberger et al., 2015). Todos esses modelos possuem implementações a versões pré-treinadas disponíveis em diferentes plataformas, e a documentação associada é detalhada e acessível (Barbedo, 2021).

Como resultado dessa disponibilidade, o número de artigos publicados na literatura que usam arquiteturas de aprendizado profundo vem aumentando continuamente (Barbedo, 2021). O problema com essa situação é que essas técnicas são aplicadas sem as precauções necessárias para evitar resultados não realistas ou enviesados. Na verdade, muitos artigos encontrados na literatura apresentam graves erros metodológicos, indicando que mesmo os revisores têm um conhecimento incompleto sobre o assunto. Um estudo detalhado sobre os principais problemas metodológicos encontrados na literatura foi publicado recentemente por (Barbedo, 2021). O objetivo deste texto é discutir mais a fundo os principais aspectos a serem considerados em cada passo do fluxo de trabalho normalmente adotado no treinamento de modelos de aprendizado profundo (Figura 1), com especial atenção dedicada aos muitos obstáculos que podem tornar os modelos gerados inadequados para uso prático.

Captura das Imagens

Variabilidade dos Dados

Muitas tecnologias falham porque os modelos nos quais estes são baseados são treinados com dados que representam apenas uma pequena parte da variedade de situações

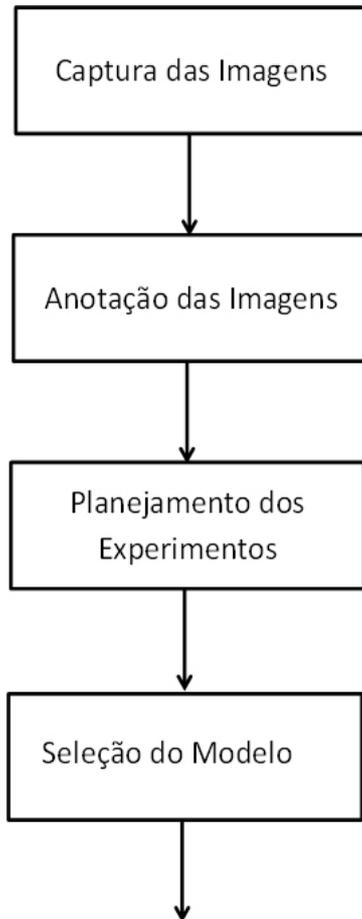


Figura 1. Fluxo de trabalho normalmente adotado para treinamento de modelos de aprendizado profundo.

encontradas na prática. Assim, um desafio a ser vencido é construir bases de imagens que representem de maneira apropriada a variabilidade do problema a ser resolvido. Isto é particularmente difícil de ser alcançado no caso da agricultura, porque não só é difícil obter as imagens em campo, como há vários fatores que introduzem variações. Alguns desses fatores têm impacto significativo e devem sempre ser considerados:

- Fundo da imagem: é virtualmente impossível incluir todos os tipos possíveis de fundos em um conjunto de dados devido à variedade de objetos que podem estar presentes no campo de visão da câmera (Mohanty et al., 2016; Barbedo, 2018a; Ferentinos, 2018). Porém, é possível reduzir o impacto do fundo fazendo com que o objeto de interesse ocupe a maior parte do campo de visão quando as imagens são capturadas.

- Condições de iluminação: as condições de iluminação em campo podem variar consideravelmente devido a fatores como ângulo de insolação, sombras e reflexões especulares. Na prática, é difícil garantir que os usuários de uma potencial tecnologia evitarão capturar imagens sob condições de iluminação extremas, de modo que os modelos precisam estar preparados para lidar com imagens subótimas.

- Variações intraclasse: certas classes podem apresentar diferentes características visuais dependendo de vários fatores. Como resultado, a gama de características visuais associadas a uma dada classe pode ser ampla, e o conjunto de treinamento deve refletir isso a fim de produzir um modelo robusto.

- Diferenças geográficas: as características particulares de uma dada área podem também alterar a aparência visual de uma dada classe. A maneira mais efetiva de lidar com o problema é pela coleta de imagens em tantos locais diferentes quanto seja possível.

- Configurações dos sensores e câmeras: câmeras possuem diversos parâmetros que podem ser definidos manualmente ou automaticamente de modo a produzir imagens com a melhor qualidade possível. Apesar de existirem técnicas de pré-processamento capazes de compensar parcialmente as variações causadas por diferentes configurações, normalmente a variabilidade associada ainda é suficientemente elevada para causar problemas ao modelo. Portanto, a captura de imagens usando várias câmeras diferentes é recomendável.

- Operação da câmera: o fator humano também tem papel importante no processo de captura das imagens. Mesmo quando os operadores são treinados para capturar as imagens de acordo com certos protocolos, existirão diferenças na maneira como a câmera é manuseada, no enquadramento da região de interesse e na firmeza das mãos, entre outros (Barbedo, 2018a). É quase impossível capturar todos os comportamentos possíveis para os operadores, mas quanto maior o número de pessoas participando do processo de captura, mais robustos tenderão a ser os modelos.

Protocolos de Captura das Imagens

Uma maneira potencial de reduzir a variabilidade associada a um dado problema e, conseqüentemente, de reduzir o número de fatores a serem considerados quando o conjunto de treinamento é construído, é impor alguns protocolos de captura. Em particular, as condições de iluminação poderiam ser parcialmente controladas fazendo com que as imagens sejam capturadas somente em certos horários do dia, sob condições

meteorológicas específicas e evitando a presença de sombras e reflexões especulares. Além disso, o fundo da imagem poderia ser significativamente simplificado pelo uso de um anteparo uniforme atrás do objeto de interesse. Apesar dessas duas ações poderem remover uma grande parte da variabilidade encontrada em imagens capturadas em campo, elas possuem algumas desvantagens. A captura de imagens em campo normalmente é uma questão de oportunidade. A necessidade de se esperar pelas condições certas pode levar a oportunidades perdidas que podem não se repetir. Isso também pode fazer com que as pessoas envolvidas na coleta de imagens percam interesse na tarefa. Por sua vez, o uso do anteparo para simplificar o fundo da imagem pode perturbar e alterar as características visuais do objeto de interesse, além de tornar o processo de captura das imagens mais complexo e demorado. Outras ações para reduzir a variabilidade normalmente causam problemas semelhantes. Em geral, o curso de ação mais apropriado é evitar protocolos que aumentam a complexidade do processo, a menos que o fator que introduz variações seja muito prejudicial, ou que os modelos a serem gerados sejam utilizados em situações específicas (por exemplo, com o propósito de auxiliar em pesquisa).

Anotação das Imagens

Uma parte essencial do desenvolvimento e treinamento do modelo é a anotação dos dados de referência com as classes corretas e possivelmente outras informações relevantes. Há muitos desafios envolvidos nessa tarefa, mas dois são mais relevantes. Primeiro, às vezes mesmo pessoas experientes têm dificuldades em identificar corretamente a classe presente nas imagens, o que pode levar a erros de rotulagem e, conseqüentemente, a falhas no treinamento (Barbedo, 2018a, 2021). Segundo, a tarefa de anotação é inerentemente subjetiva e, como resultado, é sujeita a fenômenos psicológicos e cognitivos que podem levar a vieses, ilusões de ótica e, em última análise, ao erro (Bock et al., 2010, 2020). Apesar de existirem algumas ferramentas para ajudar no processo de anotação (Verma et al., 2020), estas têm capacidade limitada de mitigar esses problemas. A solução mais apropriada em ambos os casos é empregar várias pessoas no processo, e então aplicar um sistema de votação sempre que houver dissensão. Esse ato tende a reduzir inconsistências no processo de anotação, melhorando assim a qualidade e confiabilidade do conjunto de dados e dos modelos treinados.

Planejamento dos Experimentos

Experimentos envolvendo aprendizado profundo precisam ser planejados cuidadosamente de modo a que o melhor modelo seja obtido após todo o processo. Dentre os aspectos que precisam ser considerados, alguns são particularmente importantes:

- Arquiteturas: à medida que o aprendizado evolui, novas arquiteturas surgem e novas estruturas são incorporadas aos modelos. Além das arquiteturas padrão, é possível combinar diferentes elementos de modo a criar arquiteturas específicas para o

problema sendo tratado. A decisão sobre qual estratégia adotar depende de alguns fatores. Arquiteturas personalizadas têm o potencial de obter resultados melhores, porém a obtenção da estrutura ideal pode requerer um longo processo experimental, sem que haja a garantia de que o desempenho será melhor que aquele obtido por arquiteturas padrão. Caso se decida pelo uso das arquiteturas já existentes, deve-se ter em mente que em geral há um compromisso entre desempenho e complexidade e tamanho da rede. A seleção da arquitetura ideal depende de uma análise cuidadosa desses fatores.

- Transferência de aprendizado (transfer learning): a maioria das arquiteturas padrão são disponibilizadas já pré-treinadas usando bases de dados como a ImageNet (Deng et al., 2009). A transferência de aprendizado normalmente funciona bem, sendo efetiva em acelerar significativamente a convergência das redes. Embora existam casos específicos em que o treinamento “do zero” é uma opção melhor, a maioria dos estudos indica que a transferência de aprendizado como a melhor opção na maioria dos casos (Boulent et al., 2019).

- Parâmetros a serem otimizados: redes neurais profundas possuem uma série de parâmetros que podem ser otimizados, como o tamanho do minibatch, taxa de aprendizado e tamanho da entrada, entre outros. Como o treinamento de redes profundas pode ser bastante demorado, testar todas as diferentes combinações de parâmetros normalmente é inviável. Em geral, a melhor estratégia é testar alguns parâmetros julgados mais relevantes separadamente até que sejam encontrados os valores mais apropriados.

- Aumentação de imagens: aumento de dados é frequentemente aplicada a conjuntos de imagens a fim de aumentar artificialmente o tamanho do conjunto de dados e a variabilidade dos dados usados para treinamento. Aumentação pode também ser utilizada para corrigir desequilíbrios entre classes. As operações de aumento mais comuns incluem a rotação, inversão e deslocamento de imagens, equalização de histograma, expansão de contraste e equalização adaptativa (Barbedo, 2018b). Aumentação pode ser uma ferramenta valiosa, especialmente quando o conjunto de imagens é relativamente pequeno. Porém, este tipo de técnica não deve ser utilizado indiscriminadamente. Aumentação deve ser aplicada apenas ao conjunto de treinamento. É possível aplicar aumento ao conjunto de teste após a divisão em subconjuntos, mas na maioria dos casos essa ação é supérflua. Se a aumento é aplicada antes da separação dos conjuntos de treinamento e teste, a divisão aleatória pode fazer com que as mesmas imagens, apenas com algumas pequenas variações, estejam presentes em ambos os conjuntos, causando um viés significativo nos resultados. Infelizmente, há muitos artigos publicados que usam esta estratégia incorreta, o que vem frequentemente sendo utilizado como justificativa para a adoção desta estratégia por outros (Sladojevic et al., 2016; Liu et al., 2018; Zhang et al., 2018; Jiang et al., 2019).

- Proporção de treinamento e teste: as proporções entre os conjuntos de treinamento e teste mais utilizadas são 70%/30% e 80%/20%. Em alguns casos, os estudos fazem uso também de um conjunto de validação, normalmente composto por 10% do total de amostras, a fim de testar a acurácia do modelo durante o processo de treinamento. Essas proporções estão bem estabelecidas e, em geral, não precisam ser alteradas.

- Validação cruzada: validação cruzada é de fundamental importância para produzir resultados confiáveis. Em particular nos casos em que o conjunto de dados não possui

muita variação, se uma única partição de dados é usada, as distribuições dos conjuntos de treinamento e teste podem apresentar vieses, inadvertidamente favorecendo ou penalizando os modelos sendo comparados. Em outras palavras, vies acarretado pelas distribuições de dados nos conjuntos de treinamento e teste pode levar a resultados fortemente enviesados e não realistas. A maneira mais efetiva de evitar isso é por meio da aplicação de validação cruzada com ao menos 5 subconjuntos (5-fold) (Sladojevic et al., 2016; Brahim et al., 2017; Lu et al., 2017; Picon et al., 2019), mas muitos estudos não aplicam esta estratégia (Ramcharan et al., 2017; Ferentinos, 2018; Liu et al., 2018; Jiang et al., 2019; Too et al., 2019; Argües et al., 2020; Chen et al., 2020; Darwish et al., 2020; Esgario et al., 2020; Li et al., 2020; Zhong, Zhao, 2020). É importante notar que em muitos casos a validação cruzada não é aplicada devido ao tempo necessário para treinar modelos adicionais, mas tal decisão nunca deveria ser tomada à custa da confiabilidade dos modelos.

- Conjuntos de dados independentes: covariate shift é o fenômeno no qual diferenças nas distribuições dos dados usados para treinar o modelo e dos dados usados para testar/validar o modelo resulta em baixa acurácia (Barbedo, 2017, 2018a, 2018b, 2021). Em muitos casos, apesar das amostras de teste, validação e treinamento serem distintas, normalmente estas provêm da mesma base de imagens, naturalmente apresentando certa correlação entre si. De fato, alguns autores observaram importantes quedas na acurácia quando o modelo treinado foi aplicado a diferentes bases de imagens (Mohanty et al., 2016; Ferentinos, 2018). Há algumas maneiras de mitigar esse tipo de problema, especialmente por técnicas de adaptação de domínio (Ben-David et al., 2010), mas para resultados mais realistas, é sempre recomendável ter uma base de dados separada para testar os modelos (Chen et al., 2020; Lee et al., 2020).

Seleção do Modelo

Dentre os fatores que devem ser considerados para pautar a seleção final do modelo, três se destacam:

- Acurácia: há diversas possíveis medidas para a acurácia de um modelo, dependendo do tipo de problema considerado, como precisão e revocação no caso de problemas de classificação e interseção sobre união (Intersection over Union - IoU) no caso de problemas de segmentação. Acurácia é o critério mais óbvio para a escolha do modelo, porém isoladamente pode não ser suficiente para indicar a melhor opção.

- Complexidade do modelo: o processo de treinamento de redes neurais profundas é quase sempre computacionalmente intensivo, podendo requerer dias ou mesmo semanas dependendo do equipamento e quantidade de dados utilizados. Embora a maioria dos modelos possa ser executada até mesmo em equipamentos com poder computacional limitado, aplicações em tempo real podem requerer modelos mais leves para serem viáveis.

- Generalidade: em algumas circunstâncias, modelos podem apresentar acurácias muito elevadas durante seu desenvolvimento, falhando contudo quando aplicados na prática. Como os dados utilizados para treinamento quase sempre possuem algumas lacunas em sua representatividade (Barbedo, 2021), é importante que a arquitetura uti-

lizada possui uma boa capacidade de generalização para lidar com tais casos omissos. Esse não é um fator fácil de avaliar, porém é de fundamental importância para avaliar o potencial do modelo. Esse item destaca mais uma vez a importância de se utilizar conjuntos de dados independentes para avaliar os modelos, como discutido na seção anterior.

Conclusão

O uso de redes neurais profundas aplicadas a problemas agrícolas vem crescendo de forma constante ao longo dos últimos dez anos. Embora os passos para tal sejam relativamente simples de serem seguidos, há diversos detalhes metodológicos que muitas vezes são ignorados, levando a resultados pouco confiáveis. O objetivo deste texto foi apresentar um guia apresentando as principais características de cada passo, bem como os principais cuidados a serem tomados em cada etapa.

Referências

ARGÜESO, D.; PICON, A.; IRUSTA, U.; MEDELA, A.; SAN-EMETERIO, M. G.; BERECIARTUA, A.; ALVAREZ-GILA, A. Few-shot learning approach for plant disease classification using images taken in the field. **Computers and Electronics in Agriculture**, v. 175, p. 1-8, Aug. 2020. DOI: 10.1016/j.compag.2020.105542.

BADRINARAYANAN, V.; KENDALL, A.; CIPOLLA, R. SegNet: a deep convolutional encoder-decoder architecture for image segmentation. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 39, n. 12, p. 2481-2495, Dec. 2017. DOI: 10.1109/TPAMI.2016.2644615.

BARBEDO, J. G. A. A new automatic method for disease symptom segmentation in digital photographs of plant leaves. **European Journal of Plant Pathology**, v. 147, n. 2, p. 349–364, Feb. 2017. DOI: 10.1007/s10658-016-1007-6.

BARBEDO, J. G. A. Deep learning applied to plant pathology: the problem of data representativeness. **Tropical Plant Pathology**, 2021. DOI: 10.1007/s40858-021-00459-9.

- BARBEDO, J. G. A. Digital image processing techniques for detecting, quantifying and classifying plant diseases. **SpringerPlus**, v. 2, p. 1-12, 2013. DOI: 10.1186/2193-1801-2-660.
- BARBEDO, J. G. A. Factors influencing the use of deep learning for plant disease recognition. **Biosystems Engineering**, v. 172, p. 84–91, 2018. DOI: 10.1016/j.biosystemseng.2018.05.013.
- BARBEDO, J. G. A. Impact of dataset size and variety on the effectiveness of deep learning and transfer learning for plant disease classification. **Computers and Electronics in Agriculture**, v. 153, p. 46–53, Oct. 2018. DOI: 10.1016/j.compag.2018.08.013.
- BARBEDO, J. G. A. Plant disease identification from individual lesions and spots using deep learning. **Biosystems Engineering**, v. 180, p. 96–107, Apr. 2019. DOI: 10.1016/j.biosystemseng.2019.02.002.
- BEN-DAVID, S.; BLITZER, J.; CRAMMER, K.; KULESZA, A.; PEREIRA, F.; VAUGHAN, J. W. A theory of learning from different domains. **Machine Learning**, v. 79, n. 1-2, p. 151–175, May 2010. DOI: 10.1007/s10994-009-5152-4.
- BOCK, C. H.; BARBEDO, J. G. A.; DEL PONTE, E. M.; BOHNENKAMP, D.; MAHLEIN, A. K. From visual estimates to fully automated sensor-based measurements of plant disease severity: status and challenges for improving accuracy. **Phytopathology Research**, v. 2, n. 9, 2020. DOI: 10.1186/s42483-020-00049-8.
- BOCK, C. H.; POOLE, G. H.; PARKER, P. E.; GOTTWALD, T. R. Plant disease severity estimated visually by digital photography and image analysis, and by hyperspectral imaging. **Critical Reviews in Plant Sciences**, v. 29, n. 2, p. 59-107, 2010. DOI: 10.1080/07352681003617285.
- BOULENT, J.; FOUCHER, S.; THÉAU, J.; ST-CHARLES, P. L. Convolutional neural networks for the automatic identification of plant diseases. **Frontiers in Plant Sciences**, v. 10, p. 1-15, July 2019. DOI: 10.3389/fpls.2019.00941.
- BRAHIMI, M.; BOUKHALFA, K.; MOUSSAOUI, A. Deep learning for tomato diseases: classification and symptoms visualization. **Applied Artificial Intelligence**, v. 31, n. 4, p. 299–315, 2017. DOI: 10.1080/08839514.2017.1315516.
- CHEN, J.; CHEN, J.; ZHANG, D.; SUN, Y.; NANEHKARAN, Y. A. Using deep transfer learning for image-based plant disease identification. **Computers and Electronics in Agriculture**, v. 173, p. 1-11, June 2020. DOI: 10.1016/j.compag.2020.105393.
- CHEN, L. C.; PAPANDREOU, G.; SCHROFF, F.; ADAM, H. **Rethinking atrous convolution for semantic image segmentation**. 2017. Disponível em: <<https://arxiv.org/pdf/1706.05587.pdf>>. Acesso em: 20 out. 2021.
- CHOLLET, F. Xception: deep learning with depthwise separable convolutions. In: IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, 30., 2017, Honolulu. **Proceedings...** Los Alamitos: IEEE, 2017. p. 1800–1807. CVPR 2017. DOI: 10.1109/CVPR.2017.195.
- DARWISH, A.; EZZAT, D.; HASSANIEN, A. E. An optimized model based on convolutional neural networks and orthogonal learning particle swarm optimization algorithm for plant diseases diagnosis. **Swarm and Evolutionary Computation**, v. 52, p. 1-12, Feb. 2020. DOI: 10.1016/j.swevo.2019.100616.

DENG, J.; DONG, W.; SOCHER, R.; LI, L. J.; LI, K.; FEI-FEI, L. Imagenet: a large-scale hierarchical image database. In: IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, 2009, Miami. **Conference proceedings**. Piscataway: IEEE, 2009. p. 248–255. CVPR 2009. DOI: 10.1109/CVPR.2009.5206848.

ESGARIO, J. G. M.; KROHLING, R. A.; VENTURA, J. A. Deep learning for classification and severity estimation of coffee leaf biotic stress. **Computers and Electronics in Agriculture**, v. 169, p. 1-9, Feb. 2020. DOI: 10.1016/j.compag.2019.105162.

FERENTINOS, K. P. Deep learning models for plant disease detection and diagnosis. **Computers and Electronics in Agriculture**, v. 145, p. 311–318, Feb. 2018. DOI: 10.1016/j.compag.2018.01.009.

HE, K.; GKIOXARI, G.; DOLLAR, P.; GIRSHICK, R. Mask R-CNN. In: IEEE INTERNATIONAL CONFERENCE ON COMPUTER VISION, 2017, Venice. **Proceedings...** Los Alamitos: IEEE, 2017. p. 2961-2969. ICCV 2017. DOI: 10.1109/ICCV.2017.322.

JIANG, P.; CHEN, Y.; LIU, B.; HE, D.; LIANG, C. Real-time detection of apple leaf diseases using deep learning approach based on improved convolutional neural networks. **IEEE Access**, v. 7, p. 59069–59080, 2019. DOI: 10.1109/ACCESS.2019.2914929.

JOHANNES, A.; PICON, A.; ALVAREZ-GILA, A.; ECHAZARRA, J.; RODRIGUES-VAAMONDE, S.; NAVAJAS, A. D.; ORTIZ-BARREDO, A. Automatic plant disease diagnosis using mobile capture devices, applied on a wheat use case. **Computers and Electronics in Agriculture**, v. 138, p. 200–209, June 2017. DOI: 10.1016/j.compag.2017.04.013.

KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. ImageNet classification with deep convolutional neural networks. In: ANNUAL CONFERENCE ON NEURAL INFORMATION PROCESSING SYSTEMS, 6., 2012, Lake Tahoe. **Proceedings...** Red Hook: Curran Associates, 2013. p. 1097-1105. NIPS 2012. (Advances in neural information processing systems, 25).

LEE, S. H.; GOËAU, H.; BONNET, P.; JOLY, A. New perspectives on plant disease characterization based on deep learning. **Computers and Electronics in Agriculture**, v. 170, p. 1-12, Mar. 2020. DOI: 10.1016/j.compag.2020.105220.

LI, D.; WANG, R.; XIE, C.; LIU, L.; ZHANG, J.; LI, R.; WANG, F.; ZHOU, M.; LIU, W. A recognition method for rice plant diseases and pests video detection based on deep convolutional neural network. **Sensors**, v. 20, n. 3, p. 1-21, Feb. 2020. DOI: 10.3390/s20030578.

LIU, B.; ZHANG, Y.; HE, D.; LI, Y. Identification of apple leaf diseases based on deep convolutional neural networks. **Symmetry**, v. 10, n. 1, p. 1-16, Jan. 2018. DOI: 10.3390/sym10010011.

LU, Y.; YI, S.; ZENG, N.; LIU, Y.; ZHANG, Y. Identification of rice diseases using deep convolutional neural networks. **Neurocomputing**, v. 267, p. 378–384, Dec. 2017. DOI: 10.1016/j.neucom.2017.06.023.

MOHANTY, S. P.; HUGHES, D. P.; SALATHÉ, M. Using deep learning for image-based plant disease detection. **Frontiers in Plant Science**, v. 7, p. 1-10, Sept. 2016. DOI: 10.3389/fpls.2016.01419.

PICON, A.; ALVAREZ-GILA, A.; SEITZ, M.; ORTIZ-BARREDO, A.; ECHAZARRA, J.; JOHANNES, A. Deep convolutional neural networks for mobile capture device-based crop disease classification in the wild. **Computers and Electronics in Agriculture**, v. 161, p. 280–290, June 2019. DOI: 10.1016/j.compag.2018.04.002.

RAHMAN, C. R.; ARKO, P. S.; ALI, M. E.; IQBAL KHAN, M. A.; APON, S. H.; NOWRIN, F.; WASIF, A. Identification and recognition of rice diseases and pests using convolutional neural networks. **Biosystems Engineering**, v. 194, p. 112–120, June 2020. DOI: 10.1016/biosystemseng.2020.03.020.

RAMCHARAN, A.; BARANOWSKI, K.; MCCLOSKEY, P.; AHMED, B.; LEGG, J.; HUGHES, D. P. Deep learning for image-based cassava disease detection. **Frontiers in Plant Science**, v. 8, p. 1-7, Oct. 2017. DOI: 10.3389/fpls.2017.01852.

REDMON, J.; FARHADI, A. **YOLOv3**: an incremental improvement. 2018. Disponível em: <<https://arxiv.org/pdf/1804.02767.pdf>>. Acesso em: 20 out. 2021.

RONNEBERGER, O.; FISCHER, P.; BROX, T. U-net: convolutional networks for biomedical image segmentation. In: INTERNATIONAL CONFERENCE, 18., 2015, Munich. **Medical image computing and computer-assisted intervention**: proceedings. Cham: Springer, 2015. p. 234-241. MICCAI 2015. (Lecture notes in computer science, 9351). DOI: 10.1007/978-3-319-24574-4_28.

SLADOJEVIC, S.; ARSENOVIC, M.; ANDERLA, A.; CULIBRK, D.; STEFANOVIC, D. Deep neural networks based recognition of plant diseases by leaf image classification. **Computational Intelligence and Neuroscience**, v. 2016, p. 1-11. DOI: 10.1155/2016/3289801.

SZEGEDY, C.; LIU, W.; JIA, Y.; SERMANET, P.; REED, S.; ANGUELOV, D.; ERHAN, D.; VANHOUCHE, V.; RABINOVICH, A. Going deeper with convolutions. In: IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, 2015, Boston. **Proceedings...** Piscataway: IEEE, 2015. p. 1-9. CVPR 2015. DOI: 10.1109/CVPR.2015.7298594.

TOO, E. C.; YUJIAN, L.; NJUKI, S.; YINGCHUN, L. A comparative study of fine-tuning deep learning models for plant disease identification. **Computers and Electronics in Agriculture**, v. 161, p. 272–279, June 2019. DOI: 10.1016/j.compag.2018.03.032.

VERMA, S.; BHATIA, A.; CHUG, A.; SINGH, A. P. Recent advancements in multimedia big data computing for iot applications in precision agriculture: opportunities, issues, and challenges. In: TANWAR, S.; TYAGI S.; KUMAR N. (Ed.). **Multimedia big data computing for IoT applications**: concepts, paradigms and solutions. Singapore: Springer, 2020. p. 391–416. DOI: 10.1007/978-981-13-8759-3_15.

ZHANG, S.; WANG, H.; HUANG, W.; YOU, Z. Plant diseased leaf segmentation and recognition by fusion of superpixel, K-means and PHOG. **Optik**, v. 157, p. 866–872, Mar. 2018. DOI: 10.1016/j.ijleo.2017.11.190.

ZHONG, Y.; ZHAO, M. Research on deep learning in apple leaf disease recognition. **Computers and Electronics in Agriculture**, v. 168, p. 1-6, Jan. 2020. DOI: 10.1016/j.compag.2019.105146.

ZOPH, B.; VASUDEVAN, V.; SHLENS, J.; LE, Q. V. learning transferable architectures for scalable image recognition. In: IEEE/CVF CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, 2018, Salt Lake City. **Proceedings...** Los Alamitos: IEEE, 2018. p. 8697-8710. CVPR 2018. DOI: 10.1109/CVPR.2018.00907.



Agricultura Digital