

Rumo à Melhoria de Produtividade e Sustentabilidade Agrícola por meio da Classificação Automática do Vigor de Sementes de Soja

Marcelo de Souza Junior¹, Rafael S. Bressan¹, Douglas F. Pereira¹,
Priscila T. M. Saito^{1,2}, Pedro H. Bugatti¹

¹Departamento de Computação Universidade Tecnológica Federal do Paraná (UTFPR) – Cornélio Procopio – PR – Brasil

²Instituto de Computação Universidade de Campinas (UNICAMP) – Campinas, SP – Brasil

{marcelojunior.2015, rafaelbressan, douglaspereira}@alunos.utfpr.edu.br
{psaito, pbugatti}@utfpr.edu.br

Abstract. *Brazil is one of the largest producers and exporters of soybeans in the world. Its great acceptance is given to its nutritional and industrial peculiarities. In view of higher productivity, the use of high quality seed is an important factor. In this sense, the tetrazolium test has been outstanding, due to its precision and speed in the evaluation of the vigor of soybean seeds. However, the analysis process is entirely related to the knowledge and experience of the seed analyst. Thus, this article aims to develop an automatic methodology for the classification of soybean seeds by means of image analysis, using computational vision techniques added to deep learning.*

Resumo. *O Brasil é um dos maiores produtores e exportadores de sementes de soja do mundo. Sua ótima aceitação é dada a suas peculiaridades nutritivas e industriais. Tendo em vista a maior produtividade, a utilização de semente de alta qualidade é um fator importante. Nesse sentido, o teste de tetrazólio têm se destacado, devido à sua precisão e rapidez na avaliação do vigor de sementes de soja. No entanto, o processo de análise é totalmente relacionado ao conhecimento e experiência do analista de semente. Dessa forma, este artigo propõe uma metodologia automática para classificação de sementes de soja por meio de análise de imagens, empregando técnicas de visão computacional agregado ao aprendizado profundo.*

Introdução

O Brasil é um dos maiores produtores e exportadores de grãos do mundo. Para a safra 2016/2017 o Brasil obteve produção de 237.671, 4 mil toneladas, em uma área plantada em 60.889, 3 mil hectares. Entre as diversas culturas semeadas, a soja se destaca, sendo a principal cultura cultivada no país, tal sucesso é dado devido sua liquidez e a possibilidade de melhores rendimentos em relação a outras culturas. A produção de soja para a safra 2016/2017 foi de 114.075, 3 mil toneladas em uma área plantada de 33.909, 4 mil hectares e um rendimento de 3.364 kg/ha, sendo por mais um ano seguido a safra recorde de recebimento de sementes soja [CONAB 2018].

Para um maior rendimento da cultura de soja, a utilização de sementes de alta qualidade é um fator primordial, pois com a utilização das mesmas, é possível o estabelecimento de plantas mais produtivas. A qualidade da semente pode variar em relação a alguns fatores, como danos mecânicos, deterioração por umidade, ataques de percevejos, entre outros [Moreano 2012]. Para o sucesso da lavoura, o controle de qualidade da indústria de sementes deve ser rápido e preciso, fornecendo resultados corretos de forma eficiente. [França-Neto et al. 1998].

Com a lentidão na obtenção dos resultados do teste de germinação, o processo de tomada de decisões na indústria de sementes torna-se limitado. Além disso, na sua forma tradicional de avaliação, o teste não fornece informações sobre o vigor da semente, e não permite a identificação das causas que afetam sua qualidade.

Dentre os testes para avaliação da qualidade fisiológica de sementes, o teste de tetrazólio tem se destacado, devido ao grande número de informações que fornece sobre os lotes de sementes, visando diagnosticar com um baixo custo, os fatores responsáveis pela redução da qualidade das mesmas [França-Neto et al. 1998]. No entanto, o teste de tetrazólio é realizado de forma manual por um analista de sementes, o qual analisa milhares de sementes por inspeção visual diariamente.

Sendo assim, a tarefa é altamente cansativa e suscetível a erros, bem como seu resultado está diretamente relacionado à prática do analista na realização da tarefa. Além disso, por tratar-se de um processo de análise visual humana, a detecção e classificação de danos pode sofrer da subjetividade intrínseca a tal processo. Um especialista em treinamento ou que apresente menor grau de especialização pode apresentar classificações divergentes em relação a um especialista com maior experiência, podendo ocasionar graves perdas de capital. Pode ocorrer também a possibilidade do processo de classificação ser enviesado de forma espúria e deliberada tanto por parte do beneficiador das sementes, como do comprador de lotes, gerando obviamente detrimento a uma das partes.

A partir de tais princípios, fica clara a necessidade de desenvolvimento de uma metodologia automática para a classificação de sementes de soja, mediante ao teste de tetrazólio, por meio de análise por imagens. Sendo assim, o presente trabalho aborda a etapa de extração de características de imagens das sementes de soja, com intuito de obter informações de interesse das mesmas, para a discriminação entre os tipos de danos sofridos durante a lavoura de soja.

A escrita do presente artigo é estruturada de forma que na Seção 2 são apresentados conceitos necessários para o entendimento da metodologia proposta no mesmo. Na Seção 3 é apresentada em detalhes a metodologia proposta. As Seções 4 e 5 explicitam, respectivamente, os experimentos realizados para a análise e validação da presente metodologia proposta e as conclusões.

Fundamentação

Para maior produtividade na safra de soja, a preocupação com a utilização de sementes de alta qualidade é um fator importante, dado que interfere diretamente no desenvolvimento da semente de soja. A análise de qualidade torna-se essencial para a identificação de sementes mais produtivas, resultando positivamente em plantas vigorosas e menos expostas a pragas e doenças, e conseqüentemente reduzindo o uso de fungicidas e agroquímicos para a proteção da cultura na lavoura.

O aprendizado profundo vem contribuindo para o estado da arte para vários problemas em geral, entre eles é bastante utilizado na solução de problemas envolvendo a análise de imagens em processos que requerem métodos de visão computacional. Nos últimos anos, rede neural por convolução (*Convolutional Neural Networks* - CNN), um dos paradigmas que envolvem o conceito de aprendizado profundo, se destacou na resolução de diversos problemas complexos (e.g. reconhecimento de dígitos manuscritos, reconhecimento de fala, reconhecimento visual de objetos, detecção de face, entre outros).

O paradigma de rede neural por convolução é motivado pelo processo biológico de percepção visual, para tanto aplica uma rede neural de múltiplas camadas (*Multilayer Perceptron* - MLP), porém não totalmente conectada como tradicionalmente aplicado na literatura [Caroline et al. 2016]. A mesma aplica campos locais de percepção por meio de neurônios que são ativados localmente em um mapa bidimensional no caso de imagens. Tal processo é realizado por meio da amplamente conhecida operação de convolução, como aplicada no espaço bidimensional em técnicas de processamento de imagens.

Nesse caso, o processo de aprendizado de tal arquitetura visa o aprendizado dos pesos das máscaras/filtros (*kernels*) aplicados ao mapa bidimensional de entrada (e.g. imagem), com o intuito de detectar características intrínsecas ao mesmo. Por exemplo, no caso de imagens, as primeiras camadas de uma CNN, durante seu processo de treinamento, aprendem pesos aos filtros especificados que sejam capazes de detectar primitivas geométricas como retas de diferentes orientações. Já em camadas posteriores, os neurônios de tais camadas são incumbidos do aprendizado de informações de maior abstração da imagem por meio da agregação das informações das camadas anteriores. Ainda considerando o exemplo de imagens, tal passo caracteriza-se como a junção de diferentes primitivas, como retas, detectando “cantos”, e assim sucessivamente em camadas posteriores à mesma, detectando então cores, texturas e formas (e.g. quadrados) mais complexas. As camadas que realizam tais operações são denominadas camadas por convolução (*convolutional layers*).

Além de tais camadas, outras podem ser aplicadas para a inclusão de certa não-linearidade ao processo de aprendizado, da mesma forma que em redes MLPs tradicionais, como por exemplo camadas de ativação que apliquem funções sigmóide ou as *Rectified Linear Unit* (ReLU), dentre outras da literatura. Outra possibilidade de aplicação de camadas ao processo refere-se às denominadas camadas de subamostragem (*pooling layers*) com o intuito tanto de diminuir o custo computacional do processo, quanto de prover maior robustez e invariância às diferenças espaciais e de escala para detecção de características dos dados de entrada [Dao-Duc et al. 2015, Shijie et al. 2017]. Geralmente, como camada de saída aplicam-se camadas sucessivas totalmente conectadas como no modelo tradicional, sendo que a última camada trata-se da aplicação de uma transformação das probabilidades do aprendizado da rede para que o mesmo seja mapeado para valores nos intervalos [0:1], para tanto pode-se utilizar a função conhecida como *softmax*, bem como outras existentes na literatura.

Existem inúmeras arquiteturas CNN propostas por diversos trabalhos na literatura. De maneira geral, a definição de tais arquiteturas recai sobre o mesmo empirismo da definição de arquiteturas tradicionais MLPs que são altamente dependentes do problema. Para [Bezerra 2016], a forma mais simples para arquitetar uma CNN é organizá-la em

etapas. Cada etapa é constituída por uma ou mais camadas de convolução em sequência, seguidas por uma camada de subamostragem, que por sua vez pode, opcionalmente, ser normalizada por meio de uma camada de normalização, como por exemplo utilizando métodos de regularização baseados na norma L_2 , dentre outros.

Segundo [Albawi et al. 2017] o ponto de vista mais benéfico das redes neurais por convolução é a redução do número de parâmetros, ao comparar a quantidade dos mesmos em relação às arquiteturas MLPs tradicionais.

Metodologia Proposta

Na presente seção são descritas as etapas para a atingir os objetivos do atual trabalho, elucidando para tanto a metodologia proposta. A Figura 1 ilustra o *pipeline* proposto para o desenvolvimento do presente trabalho. A metodologia é dividida em quatro etapas principais.

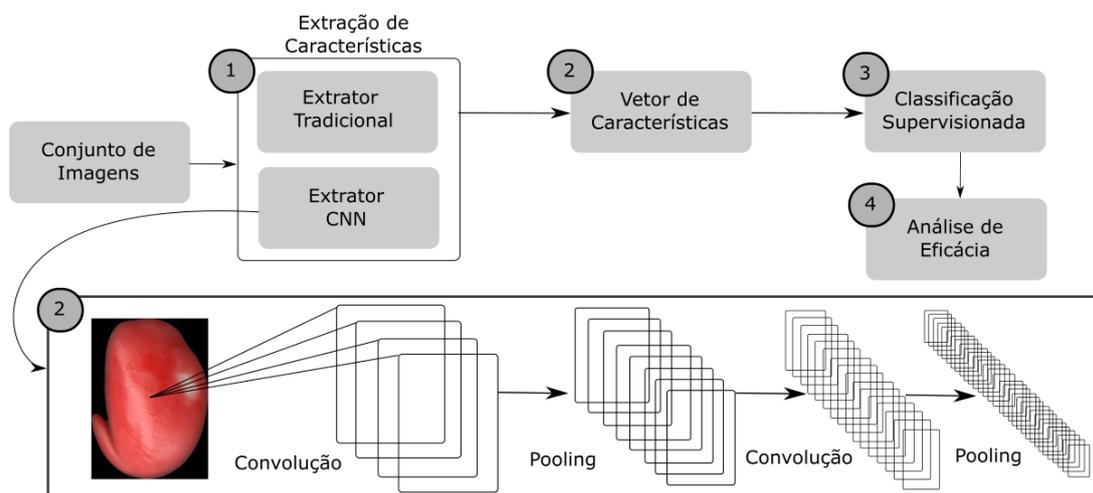


Figura 1. *Pipeline* da metodologia proposta.

A primeira etapa consiste em realizar a extração de características intrínsecas das imagens. Para tanto, foram extraídas características *hand-crafted*, por meio de descritores de imagens tradicionais de baixo nível (baseados em cor e textura). Apenas características baseadas em cor e textura foram extraídas, uma vez que para a descrição dos danos em sementes, geralmente, a forma das mesmas não apresenta alterações. Além disso foram extraídas as características *deep*, utilizando arquiteturas CNN. Para tanto, foi aplicado o processo de *transfer learning* [Yosinski et al. 2014] e consideradas diferentes arquiteturas pré-treinadas a partir do conjunto de imagens do *ImageNet* [Deng et al. 2009].

Em seguida, na Etapa 2, são gerados os vetores de características para cada técnica de extração (Tabela 2). Após tal passo, os mesmos são submetidos à terceira etapa, na qual são gerados os respectivos conjuntos de treinamento e teste para cada um dos conjuntos de características obtidos. Tais conjuntos de treinamento e teste são então submetidos ao processo de aprendizado supervisionado. Diferentes modelos de classificação são gerados a partir dos conjuntos de treinamento e diferentes técnicas de classificação. Por fim, na Etapa 4 é realizada a análise de desempenho das diferentes técnicas de extração de

características e de classificação. O Algoritmo 1 apresenta em detalhes a metodologia proposta.

Algorithm 1: Metodologia proposta

Entrada : conjunto de imagens I
Saida : conjunto de acurácias \mathcal{A}_{ij}
Auxiliares: conjuntos de características tradicionais HandCrafted_s , conjunto E_s de extratores tradicionais, conjuntos de características CNN Deep_l , conjunto \mathcal{T}_l de arquiteturas CNN, conjunto \mathcal{F} com características HandCrafted_s e Deep_l , conjuntos de treinamento \mathcal{Z}_i , modelos de aprendizado \mathcal{M}_{ij} , conjunto de técnicas de classificação \mathcal{C}

- 1 $\text{HandCrafted}_s \leftarrow \text{extracaoTrad}(I, E_s)$;
- 2 $\text{Deep}_l \leftarrow \text{extracaoCNN}(I, \mathcal{T}_l)$;
- 3 $\mathcal{F}_n \leftarrow \{\text{HandCrafted}_s\} \cup \{\text{Deep}_l\}$;
- 4 **for** cada $i \in \mathcal{F}$, $i = 1, \dots, n$ **do**
- 5 $\mathcal{Z}_i \leftarrow \mathcal{F}_i$;
- 6 **for** cada $j \in \mathcal{C}$, $j = 1, \dots, m$ **do**
- 7 $\mathcal{M}_{ij} \leftarrow \text{treinamento}(\mathcal{Z}_i, \mathcal{C}_j)$;
- 8 $\mathcal{A}_{ij} \leftarrow \text{desempenho}(\mathcal{M}_{ij})$;
- 9 **end**
- 10 **end**

Experimentos

Descrição do Conjunto de Imagens

Para a realização dos experimentos do presente trabalho foi utilizado um conjunto de imagens de sementes de soja submetidas ao teste de tetrazólio. O conjunto é composto por 1.333 imagens distribuídas em 10 classes. A Tabela 1 ilustra a quantidade de imagens em cada classe do conjunto de imagens. A Figura 2 ilustra exemplos de imagens de sementes de soja, após aplicação do teste de tetrazólio, com diferentes tipos de danos.

Para melhor entendimento de tais classes foi especificada uma nomenclatura para o nome das mesmas, a qual é definida por 3 caracteres. O primeiro caractere especifica o grau do dano (0 a 3), sendo que quanto maior o valor, maior o dano apresentado na semente. O segundo caractere descreve o tipo do dano encontrado na semente. Por exemplo, o caractere U descreve um dano causado por umidade excessiva, o caractere M representa um dano mecânico (i.e. quando a semente pode apresentar uma fratura ou porção faltante), o caractere P denota um dano causado por percevejos. Já o caractere X especifica a ausência de danos na semente (i.e. semente perfeita), por tal motivo sempre que houver o caractere X , o mesmo estará agregado ao caractere de grau de dano 0. Tal redundância foi gerada para manter a padronização da quantidade de caracteres na definição das classes, uma vez que na prática não existe um dano de grau 0. Por fim, o terceiro caractere especifica a porção da semente capturada, visto que para a análise do vigor baseada no teste de tetrazólio é necessário avaliar tanto a porção externa da semente (denotada pelo caractere E) como a porção interna da mesma (caractere I).

Todas as imagens foram rotuladas e validadas por especialistas durante a análise das sementes. Tais especialistas pertencem a um laboratório de análises inserido em uma unidade de beneficiamento de sementes (UBS) de soja. Tal UBS caracteriza-se dentre uma das maiores unidades beneficiadoras de sementes de soja do país, a qual gera impacto na produção de inúmeros produtores de soja no Brasil.

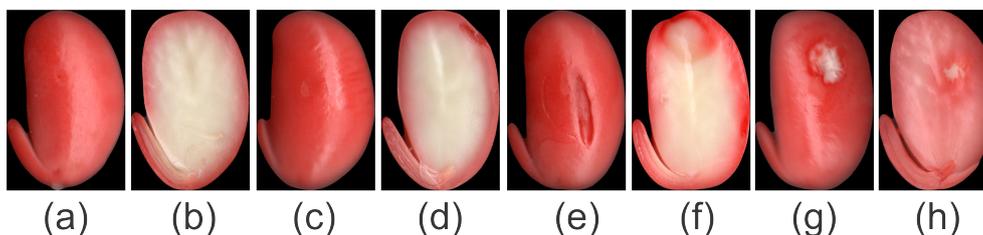


Figura 2. Exemplo de imagens de sementes de soja submetidas ao teste de tetrazólio apresentando diferentes tipos de danos: (a) Perfeita porção externa; (b) Perfeita porção interna; (c) Dano por umidade porção externa; (d) Dano por umidade porção interna; (e) Dano mecânico porção externa; (f) Dano mecânico porção interna; (g) Dano por percevejo porção externa; (h) Dano por percevejo porção interna.

Tabela 1. Descrição do conjunto de imagens, com suas respectivas classes, tipos de danos e quantidade de amostras.

Classe	Descrição	#Amostras
1 - 0XE	Perfeita porção externa	502
2 - 0XI	Perfeita porção interna	529
3 - 2UE	Dano por umidade nível 2 porção externa	23
4 - 2UI	Dano por umidade nível 2 porção interna	7
5 - 3ME	Dano mecânico nível 3 porção externa	36
6 - 3MI	Dano mecânico nível 3 porção interna	28
7 - 3PE	Dano por percevejo nível 3 porção externa	83
8 - 3PI	Dano por percevejo nível 3 porção interna	40
9 - 3UE	Dano por umidade nível 3 parte externa	36
10 - 3UI	Dano por umidade nível 3 parte interna	49

Cenários

Para extração das (*hand-crafted* e *deep*) características foram utilizados diferentes extratores. As características *deep* foram obtidas por meio das CNNs. Já as características *hand-crafted* foram obtidas por meio de extratores baseados em cor e textura. A Tabela 2 apresenta os extratores, a respectiva categoria e a quantidade de características obtidas por cada um deles. Para as arquiteturas CNNs foram utilizados os modelos providos pela biblioteca Keras¹, bem como foram utilizados os parâmetros padrão especificados pela mesma.

Para classificação foram utilizados os classificadores *Random Forest* - RF [Breiman 2001], *k-Nearest Neighbors* - *k*-NN [Cover and Hart 1967], *Support Vector Machines* - SVM [Hearst et al. 1998] e *Optimum-Path Forest* - OPF [Papa et al. 2012].

¹<https://keras.io/>

Para fins de validação, além das acurácias médias gerais, foi calculada a acurácia por cada classe, afim de analisar a quantidade de acertos de cada classificador por respectiva classe de danos. Para a obtenção de tais acurácias considerando os classificadores tradicionais foi realizado o processo de validação cruzada estratificada com 10-folds.

Tabela 2. Propriedades de cada extrator de características, especificando a categoria e a dimensionalidade dos vetores de características gerados.

Extratores	Categoria	#Caraterísticas
F ₁ - MobileNet [Howard et al. 2017]	CNN	2048
F ₂ - InceptionV3 [Szegedy et al. 2015]	CNN	2048
F ₃ - VGG16 [Simonyan and Zisserman 2014]	CNN	512
F ₄ - VGG19 [Simonyan and Zisserman 2014]	CNN	512
F ₅ - Xception [Chollet 2016]	CNN	2048
F ₆ - BIC [Stehling et al. 2002]	Cor	128
F ₇ - GCH [Stricker and Orengo 1995]	Cor	255
F ₉ - LCH [Smith and Chang 1996]	Cor	135
F ₈ - LBP [Guo et al. 2010]	Textura	256
F ₁₀ - Haralick [Haralick et al. 1973]	Textura	15
F ₁₁ - MPOC [Irons and Petersen 1981]	Textura	18

Resultados

A Tabela 3 apresenta as acurácias médias gerais em porcentagem, obtidas por cada uma das características extraídas e os respectivos classificadores supervisionados. Pode-se verificar que a maior acurácia obtida foi de 78.01%, utilizando o classificador RF com as características extraídas pela arquitetura VGG19. Além de tal resultado, nota-se também que para os classificadores RF e k -NN as características obtidas pelas diferentes arquiteturas CNNs apresentam melhores resultados em relação às características tradicionais.

Considerando as melhores acurácias atingidas por cada classificador supervisionado é possível verificar que o classificador k -NN obteve a maior acurácia (75,61%) com as características obtidas por meio da arquitetura Xception. Já para os classificadores SVM e OPF, as maiores acurácias foram obtidas, respectivamente, pelas características oriundas das arquiteturas VGG19 alcançando 78,01%, e VGG16 apresentando 69.16% de acurácia.

Além de analisar a acurácia geral do processo de classificação, mais relevante ainda é a avaliação da acurácia obtida por cada classe de imagens. Ao realizar tal análise, pôde-se verificar que, apesar dos bons resultados denotados por meio da acurácia geral dos classificadores, a acurácia específica de cada classe apresentou bons resultados apenas para as classes de sementes perfeitas (i.e. $0XE$ e $0XI$), sendo que para as classes que agregam grau e tipo do dano, bem como a porção da semente, as acurácias apresentadas foram baixas. Dessa forma, os resultados de acurácia geral obtidos por meio da primeira análise estavam camufladas pelas altas acurácias obtidas apenas pelas duas classes de imagens de sementes perfeitas.

As Figuras 3 (a)-(d) ilustram de maneira conclusiva tal constatação, sendo que as melhores acurácias obtidas, dentre as classes anteriormente citadas, foram de aproximadamente 40% para a classe $3PE$, utilizando as características *deep*, obtidas pelas arqui-

Tabela 3. Acurácias gerais obtidas, considerando cada um dos extratores e classificadores supervisionados. Valores explicitados em negrito referem-se às melhores acurácias atingidas por cada classificador. Já o valor denotado em sublinhado refere-se à melhor acurácia obtida dentre todas.

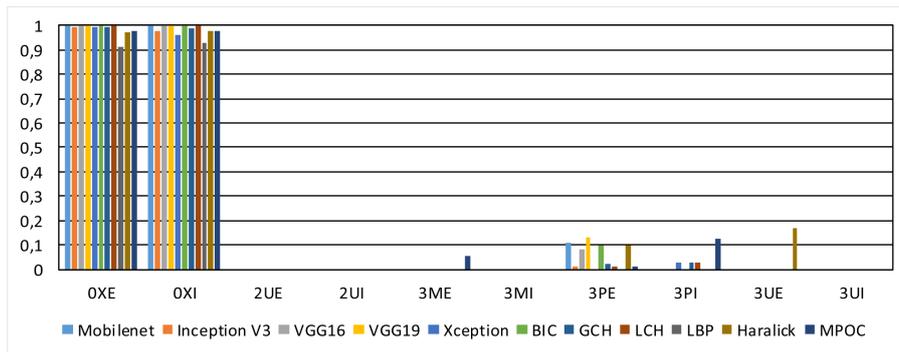
	RF	k -NN	SVM	OPF
MobileNet	77,86	68,64	72,91	66,99
InceptionV3	76,36	64,89	73,06	62,79
VGG16	77,71	69,76	76,89	69,16
VGG19	<u>78,01</u>	69,24	78,01	68,82
Xception	75,61	75,61	70,44	63,91
BIC	77,79	66,69	77,26	65,49
GCH	76,89	66,01	77,11	64,59
LCH	77,41	67,21	77,64	65,94
LBP	71,11	55,58	75,01	54,91
Haralick	76,44	65,56	77,04	63,76
MPOC	76,29	65,94	76,86	64,51

turas MobileNet e VGG16 para o classificador SVM. Já a segunda melhor acurácia, de aproximadamente 35%, foi obtida com as mesmas características e classificador para a classe 3PI. No entanto, ainda é possível perceber que as características obtidas pelas diferentes arquiteturas CNNs, geralmente, apresentam melhores resultados quando comparadas com as características tradicionais.

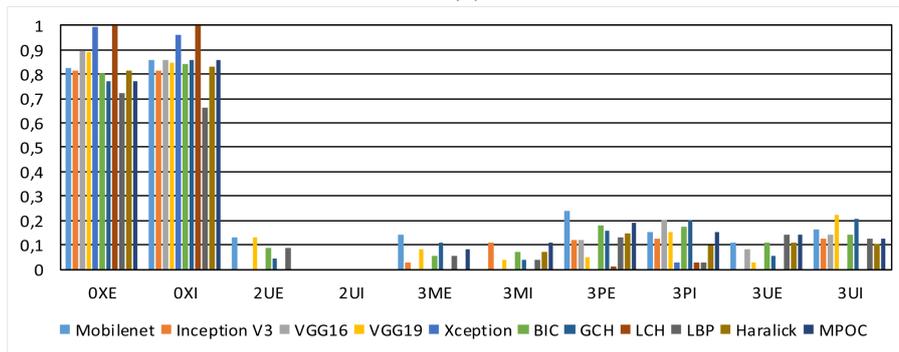
É importante ressaltar que tais resultados baixos de acurácia por classe obtidos pela metodologia proposta, podem ser justificados principalmente pelo alto desbalanceamento de imagens por classe. Ao analisar a Tabela 1, descrita na Seção 4.1, nota-se claramente o relevante desbalanceamento entre as classes. Dessa forma, como é amplamente conhecido na literatura, classificadores supervisionados geralmente apresentam resultados consideravelmente baixos quando aplicados em problemas altamente desbalanceados, fato que ocorreu no presente trabalho.

No entanto, apesar de tais resultados, vale ressaltar que o presente trabalho configura-se como uma metodologia seminal para a análise do problema de classificação do vigor de sementes de soja por meio de características tanto tradicionais como baseadas em arquiteturas profundas pré-treinadas. Além disso, a metodologia proposta foca no problema de classificação mais desafiador possível, atrelado ao contexto da definição automática do vigor de sementes de soja, uma vez que propõe em um único passo de classificação a definição de três especificidades com semânticas diferentes relacionadas às imagens, que são: nível do dano, tipo do dano e porção da semente.

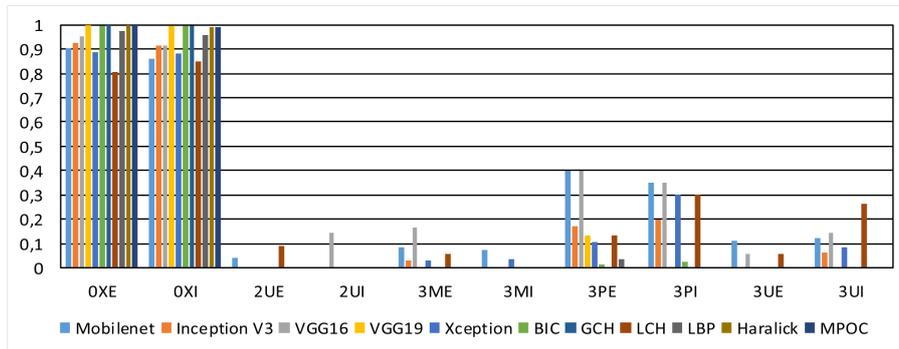
Portanto, verifica-se a partir de tal ponto outra justificativa plausível para as baixas acurácias obtidas, uma vez que trata-se de um problema hierárquico de classificação, em que sub-passos de classificação poderiam ser aplicados a cada uma das especificidades para posterior agregação de classificação. No entanto, o presente trabalho optou por traçar o caminho mais desafiador por meio da definição em único passo da classificação de todas as especificidades, com o intuito de prover melhor eficiência e escalabilidade ao processo, visto que diariamente um único especialista analisa visualmente milhares de sementes.



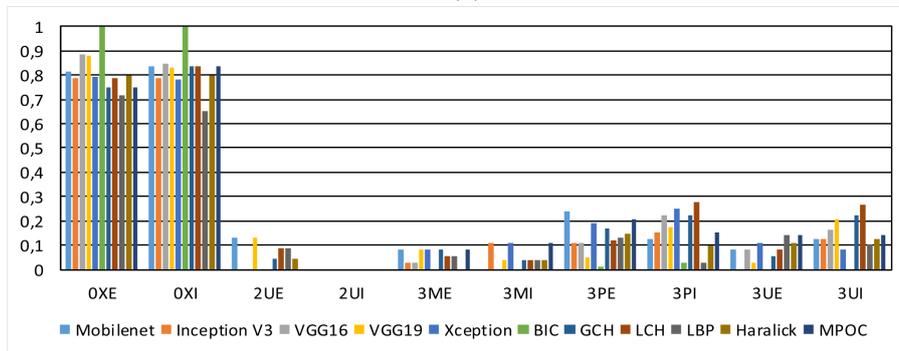
(a)



(b)



(c)



(d)

Figura 3. Médias das acurácias por classe obtidas, considerando cada um dos extratores e classificadores (a) RF, (b) k -NN, (c) SVM e (d) OPF.

Conclusão

No presente trabalho foi apresentada uma nova metodologia para a classificação automática de danos em sementes de soja submetidas ao teste de tetrazólio, e consequentemente, para a definição do vigor das mesmas. Na presente metodologia foram aplicadas tanto características tradicionais extraídas de uma base de imagens de sementes, bem como características obtidas por meio de arquiteturas CNNs pré-treinadas por meio do conceito de *transfer learning*.

A partir dos resultados obtidos pôde-se verificar o quão desafiador o problema caracteriza-se, uma vez que demanda a classificação de diferentes fatores semânticos intrínsecos à definição do vigor em sementes de soja. Tais fatores referem-se ao tipo de dano, ao nível de severidade de um dado dano, bem como à porção da semente ao qual um determinado dano é detectado. Dessa forma, visto que o processo de definição do vigor deve ser altamente escalável, dado o grande volume de dados analisados diariamente pelo analista em sementes, a presente metodologia visou aplicar em um único passo de classificação a definição conjunta de todos os fatores semânticos envolvidos no problema.

Apesar das acurácias por classe obtidas terem apresentando valores baixos, o presente trabalho abre novos caminhos para inúmeras melhorias ao processo explicitado por meio da metodologia proposta. Tais melhorias podem ser atingidas primeiramente pelo balanceamento das classes de danos. Entretanto, uma vez que não é trivial realizar tal balanceamento por meio da coleta in-situ, em que geralmente, imagens de sementes perfeitas são a regra (em virtude dos controles das unidades de beneficiamento de sementes), vislumbra-se a aplicação de técnicas de *data augmentation* para realizar tal balanceamento.

Assim, a partir dos pontos elencados, acredita-se que a presente metodologia seminal para o problema em questão, pode gerar considerável impacto na melhoria da produtividade e sustentabilidade agrícola relacionada à produção de soja no Brasil. Além disso, uma vez refinada, a mesma pode ser também utilizada como uma contraprova às definições de vigor realizadas pelo especialista, auxiliando assim o mesmo em tal processo, bem como evitando adulterações de caráter escuso nos resultados do vigor, oriundas de interesses monetários.

Agradecimentos

O presente trabalho recebeu apoios oriundos do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq): grants #472625/2014-4, #431668/2016-7, #422811/2016-5; Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES); Fundação Araucária de Apoio ao Desenvolvimento Científico e Tecnológico do Paraná; Secretaria da Ciência, Tecnologia e Ensino Superior (SETI); Belagrícola; e Universidade Tecnológica Federal do Paraná (UTFPR).

Referências

Albawi, S., Mohammed, T. A., and Al-Zawi, S. (2017). Understanding of a Convolutional Neural Network. In *Proceedings of the International Conference on Engineering and Technology*, pages 1–6.

- Bezerra, E. (2016). Introdução à Aprendizagem Profunda. In Ogasawara, V., editor, *Tópicos em Gerenciamento de Dados e Informações - Simpósio Brasileiro de Banco de Dados*, pages 57–86. Sociedade Brasileira de Computação.
- Breiman, L. (2001). Random forests. *Machine learning*, 45(1):5–32.
- Caroline, A., Vargas, G., Paes, A., and Vasconcelos, C. N. (2016). Um Estudo sobre Redes Neurais Convolucionais e sua Aplicação em Detecção de Pedestres. In *Proceedings of the Conference on Graphics, Patterns and Images*, pages 1–4.
- Chollet, F. (2016). Xception: Deep learning with depthwise separable convolutions. *arXiv preprint*.
- CONAB (2018). Companhia nacional de abastecimento: Acompanhamento da Safra Brasileira Grãos, V.5 - SAFRA 2016/17 - N.6 - Sexto Levantamento — Março 2018. *Monitoramento agrícola- Safra 2017*, 5:1–126.
- Cover, T. and Hart, P. (1967). Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, 13(1):21–27.
- Dao-Duc, C., Xiaohui, H., and Morère, O. (2015). Maritime Vessel Images Classification Using Deep Convolutional Neural Networks. In *Proceedings of the Sixth International Symposium on Information and Communication Technology*, pages 1–6. ACM Press.
- Deng, J., Dong, W., Socher, R., Li, L.-J., Kai Li, and Li Fei-Fei (2009). ImageNet: A large-scale hierarchical image database. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pages 248–255. IEEE.
- França-Neto, J. B., Krzyzanowski, F. C., and da Costa, N. P. (1998). *O Teste de Tetrazólio em Sementes de Soja*. Embrapa - Centro Nacional de Pesquisa de Soja, Londrina.
- Guo, Z., Zhang, L., and Zhang, D. (2010). Rotation invariant texture classification using LBP variance (LBPV) with global matching. *Pattern Recognition*, 43(3):706–719.
- Haralick, R. M., Shanmugam, K., and Dinstein, I. (1973). Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-3(6):610–621.
- Hearst, M. A., Dumais, S. T., Osuna, E., Platt, J., and Scholkopf, B. (1998). Support vector machines. *IEEE Intelligent Systems and their Applications*, 13(4):18–28.
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., and Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. *CoRR*, abs/1704.04861.
- Irons, J. R. and Petersen, G. W. (1981). Texture transforms of remote sensing data. *Remote Sensing of Environment*, 11:359–370.
- Moreano, T. B. (2012). *Evolução das Qualidades Física e Fisiológica da Semente de Soja no Beneficiamento*. Dissertação, Universidade Estadual de Maringá, Maringá.
- Papa, J. P., Falcão, A. X., de Albuquerque, V. H. C., and Tavares, J. M. R. S. (2012). Efficient supervised optimum-path forest classification for large datasets. *Pattern Recognition*, 45:512–520.

- Shijie, J., Ping, W., Peiyi, J., and Siping, H. (2017). Research on data augmentation for image classification based on convolution neural networks. In *Proceedings of the Chinese Automation Congress*, pages 4165–4170. IEEE.
- Simonyan, K. and Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *CoRR*, abs/1409.1556.
- Smith, J. R. and Chang, S.-F. (1996). Local color and texture extraction and spatial query. In *Proceedings of the International Conference on Image Processing*, pages 1011–1014.
- Stehling, R. O., Nascimento, M. A., and Falcão, A. X. (2002). A compact and efficient image retrieval approach based on border/interior pixel classification. In *Proceedings of the International Conference on Information and Knowledge Management*, pages 102–109.
- Stricker, M. A. and Orengo, M. (1995). Similarity of color images. In *Storage and Retrieval for Image and Video Databases III*, volume 2420, pages 381–393. International Society for Optics and Photonics.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., and Wojna, Z. (2015). Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pages 2818–2826.
- Yosinski, J., Clune, J., Bengio, Y., and Lipson, H. (2014). How transferable are features in deep neural networks? In *Proceedings of the International Conference on Neural Information Processing Systems*, pages 3320–3328.