

Visão computacional na agricultura:

APIs de detecção e reconhecimento de doenças das plantas

Dora Kaufman¹

Lenilson Lemos Vilas Boas²

Resumo: As tecnologias de inteligência artificial (IA) estão permitindo identificar com mais precisão doenças em folhas de plantas por meio da análise de imagens, com efeitos benéficos sobre a agricultura (custo, eficiência, qualidade). O artigo apresenta os resultados de estudos desenvolvidos com o uso de três tecnologias (plataformas) distintas treinadas com o mesmo conjunto de 50 imagens de quatro doenças, indicando as características visuais de cada uma delas. O treinamento foi dividido em duas etapas: a primeira realizada com 30 imagens e a segunda com 20 imagens, e a validação e a análise do aprendizado foram realizadas a partir de 10 imagens. O propósito dos testes é comparar a assertividade de reconhecimento das doenças em cada tecnologia/plataforma. As doenças examinadas para o estudo são: *Peronospora (downy mildew)*, *Diplocarpon rosae (black spot)*, Oídio (*powdery mildew*) e Cancro cítrico. Os resultados mostraram-se positivos para a identificação das doenças por meio de imagens.

Palavras-chave: Aprendizado de Máquinas. Agricultura Digital. Imagens Digitais. API. Visão Computacional.

¹ Doutora na Escola de Comunicações e Artes pela USP.
cv Lattes: lattes.cnpq.br/8045171889826285. E-mail: dkaufman@usp.br.

² Mestre em Tecnologias da Inteligência e Design Digital pela PUC-SP.
cv Lattes: lattes.cnpq.br/7560669146487395. E-mail: lenilsonvb@hotmail.com.

Computer vision in agriculture: APIs for detection and recognition of plant diseases

Abstract: Artificial intelligence (AI) technology has made it possible to identify plant leaf diseases more accurately through image analysis, with beneficial effects to agriculture (cost, efficiency, quality). The article presents the results of studies using three distinct technologies (platforms) applied to one set of 50 images of four plant diseases, showing the visual characteristics of each of them. The study was divided into two stages. The first was carried out with 30 images and the second with 20. The learning progress and the validation analysis were carried out by means of 10 frames. The purpose of testing was to compare disease recognition assertiveness on each technology / platform. Images of the following plant diseases were investigated in this study: *Peronospora* (downy mildew), *Diplocarpon rosae* (black spot), powdery mildew and Citrus Canker. The results of the identification of the diseases through images were positive.

Keywords: Machine learning. Digital agriculture. Digital imaging. API. Computer vision.

Introdução

Agregar tecnologias digitais à agricultura traz ganhos para a cadeia de produção e para o consumo, impactando positivamente o desenvolvimento dos países comprometidos com esses investimentos. Segundo Fabrício Juntolli (2017, p. 1), “cerca de 67% das propriedades agrícolas do Brasil usam algum tipo de tecnologia, seja na área de gestão dos negócios ou nas atividades de cultivo e colheita da produção”. As tecnologias digitais facilitam o acesso do agricultor às informações estratégicas, tais como umidade do solo, previsões climáticas, áreas plantadas, estágio da colheita ou dados coletados por meio de sensores, dispositivos ou outras fontes de dados como sistemas e sites da internet. O conjunto dos diversos dispositivos interconectados é conhecido como *Internet of Things*, IoT (Internet das Coisas) (cf. ATZORI, 2010). A ideia básica da IoT consiste em conectar uma diversidade de objetos que interagem e cooperam entre si a fim de atingir um objetivo comum.

A taxa de disseminação de uma doença em plantas depende das condições atuais da cultura e da suscetibilidade à infecção (LUCAS *et al.*, 1992). As plantas submetidas a algum tipo de estresse podem exibir uma série de sintomas como manchas coloridas ou raias nas folhas, nos caules e nas sementes; esses sintomas visuais alteram continuamente a cor, a forma e o tamanho à medida que a doença avança. Identificar os meios de combater pragas na agricultura precocemente é um caminho para melhorar a produção e a qualidade do produto final.

A introdução de novas tecnologias na agricultura, contudo, não elimina as técnicas tradicionais de cultivo; pelo contrário, as novas técnicas associam-se às técnicas existentes gerando ganhos de qualidade nos processos e nos resultados.

A criação de aplicações com visão computacional requer plataformas computacionais complexas, programas especializados e conhecimento na área (alternativa: sistemas disponibilizados por meio de *Application Programming Interface* — APIs). Essas APIs de visão computacional com capacidade de aprendizado como principal funcionalidade encontram padrões em imagens ou vídeos, identificando formas, cores, texturas, bor-

das ou qualquer outro elemento presente que seja o objeto desejado de identificação ou classificação.

O estudo buscou selecionar, avaliar e comparar as tecnologias disponíveis na forma de API e distribuídas por meio de plataforma como serviço (PaaS — *Platform as a Service*). Serão examinadas três plataformas cujos sistemas foram criados visando ao aprendizado e a identificação de doenças em folhas de plantas por meio de imagens.

As três tecnologias selecionadas serão treinadas com um mesmo conjunto de 50 imagens de quatro doenças distintas de folhas de plantas. Este treinamento irá fornecer as características visuais de cada uma das quatro doenças. O treinamento foi dividido em duas etapas, sendo que a primeira etapa foi realizada com um conjunto de 30 imagens e a segunda etapa com um conjunto de 20 imagens, totalizando 50 imagens.

A validação e a análise do aprendizado de cada plataforma foram realizadas a partir de um conjunto de 10 imagens de testes de plantas com as doenças objeto do estudo. Os testes de validação foram realizados após cada etapa de treinamento. Este conjunto de imagens para testes não foi considerado no treinamento de aprendizagem inicial. O propósito dos testes é comparar a assertividade de reconhecimento das doenças em cada plataforma, após receber um mesmo treinamento e testes. Pesquisas analisadas indicam que o setor agrícola vem recebendo forte investimento em automação, reduzindo, gradativamente, a atuação e intervenção humana nas rotinas rurais.

Deteção de doença de folhas de plantas por meio de processamento de imagem

Distintas técnicas podem ser empregadas para deteção e identificação de doenças em plantas, como por exemplo a técnica de “*K-Means*” utilizada para separar os *pixels* verdes da imagem (coloração da planta), identificando os *pixels* da doença (cores diferentes de verde). Esta técnica pode ser utilizada em conjunto com uma rede neural artificial para classificação da doença (SANNAKKI, 2013). Outra técnica utilizada é a segmentação de imagens dentro do espaço RGB (*Red, Green e Blue*) com bons resultados, segundo Gonzales e Woods (2000). Esse método consiste em utilizar uma amostra do conjunto de cores que representam as cores de interesse, obtendo o valor médio da cor segmentado das demais cores.

A identificação de texturas é um método já conhecido e utilizado para análise de imagem, porém agora passa a ser utilizado como uma

abordagem em visão computacional; a textura é caracterizada pela repetição de um modelo sobre uma determinada região da imagem, em sua forma exata ou com pequenas variações (HARALICK, 1973). Identificada a textura, é possível aplicar a abordagem de limiarização para segmentar a imagem. O método proposto é baseado na extração de diversas características de texturas de uma matriz de recorrência dos níveis de coloração de cinza, agrupando texturas e cores similares de cinza (MARQUES; NETO, 1999).

As etapas de processamento de imagem digitais para detecção de doenças em plantas podem ser divididas em três principais segmentos: detecção, quantificação e classificação. Para cada etapa existem diferentes técnicas que podem ser empregadas; para a detecção podem ser utilizadas as técnicas de rede neural, limiarização e análise de regressão duplamente segmentada. Para a quantificação é possível utilizar técnicas de limiarização, análise de cor, lógica *fuzzy*, base de conhecimento, crescimento da região e *softwares* de terceiros. As técnicas de classificação são divididas em redes neurais, máquinas de suporte de vetor, classificador *fuzzy*, regras de características, análise de cores, mapas auto-organizados, análise discriminante e função de membro (BARBEDO, 2013).

Uma proposta de metodologia capaz de identificar as doenças *Peronospora (downy mildew)* e *Oídio (powdery mildew)* em folhas de uva pode ser visto no trabalho de Kamlapurkar (2016). O autor apresenta a estrutura do sistema em forma sequencial: banco de dados de imagem, processamento, extração de características, classificação e diagnóstico. Essa abordagem tem como elemento principal a extração de características visuais da doença, utilizando a técnica de segmentação que separa o contorno da doença na folha por meio de contraste da imagem e deixa a doença destacada em cor branca. Assim é possível identificar a forma da doença e compará-la a imagens similares.

Um sistema robótico autônomo para mapear ervas daninhas em campos

Hansen *et al.* (2013) apresentam um projeto chamado ASETA, composto de teoria e de métodos para sistemas de robôs agrícolas. O projeto opera veículos aéreos e terrestres não tripulados (VANTs), equipados com câmeras para identificação de ervas daninhas em plantações de beterraba. A visão computacional é usada em dois momentos: (a) quando as imagens são feitas via aérea, o sistema busca identificar padrões de alteração na coloração da folhagem diferente da folhagem de objetivo de cultivo e (b) quando as imagens são feitas de forma terrestre, o sistema busca

identificar padrões no contorno e na forma não condizente das folhas das beterrabas. Uma vez identificada a cultura invasora é possível combater de forma individual o foco, diminuindo a quantidade de pesticidas utilizada e melhorando a qualidade do produto.

Foram selecionadas imagens de quatro doenças diferentes, com características visuais específicas que podem ser visualizadas e diferenciadas por seres humanos sem a necessidade de equipamento apropriado. Para cada doença foram selecionadas 60 imagens, apresentadas em diferentes ângulos e diferentes distâncias de visualização.

Os fabricantes das APIs de visão computacional desse estudo sugerem a utilização de no mínimo 30 imagens para o treinamento inicial. O relativo número reduzido de imagens pode estar relacionado ao tipo de rede neural utilizada; as redes neurais convolucionais, por exemplo, necessitam de um baixo treinamento para atingir resultados aceitáveis, análise também presente no estudo de Vargas, Paes e Vasconcelos (2016), permitindo extrair características complexas dos dados³.

As imagens selecionadas são do site *ipm images*⁴, que tem o foco em espécies invasivas, silvicultura, agricultura, manejo integrado de pragas, plantas, insetos, doenças, fungos, vida selvagem, fogo e outros itens referentes a recursos naturais. A escolha foi realizada preferencialmente por imagens que apresentassem a doença na folha ou fruto, e que não houvesse uma grande aproximação (*zoom*) da imagem. As doenças e as imagens selecionadas para o estudo são as seguintes:

Peronospora (*downy mildew*)

A doença Peronospora pode afetar diversos tipos de plantas. Ela costuma aparecer em forma de manchas amarelas ou brancas na parte superior das superfícies das folhas mais velhas. Na parte de baixo das folhas é possível notar uma cobertura de fungos de cor branca acinzentada com aspecto de algodão. A doença é notada principalmente após a chuva, podendo desaparecer em um clima mais ensolarado. A evolução da doença é caracterizada pela coloração de castanha, podendo levar a queda das folhas (Figura 1).

A Peronospora ocorre em clima frio e úmido, sendo mais comum no início da primavera ou final do outono; seus esporos ficam dormentes

³ A escolha e uso das imagens para treinamento e testes possui objetivo exploratório, não sendo objeto deste estudo identificar a quantidade ideal de imagens que devem ser utilizadas para treinamento.

⁴ Disponível em: ipmimages.org. Acesso em: 20 ago. 2019.

sobre os detritos das plantas e é transmitida por meio do manejo e transporte dos esporos por insetos, vento, chuva ou ferramentas (ENCYCLOPAEDIA BRITANNICA, 2017).

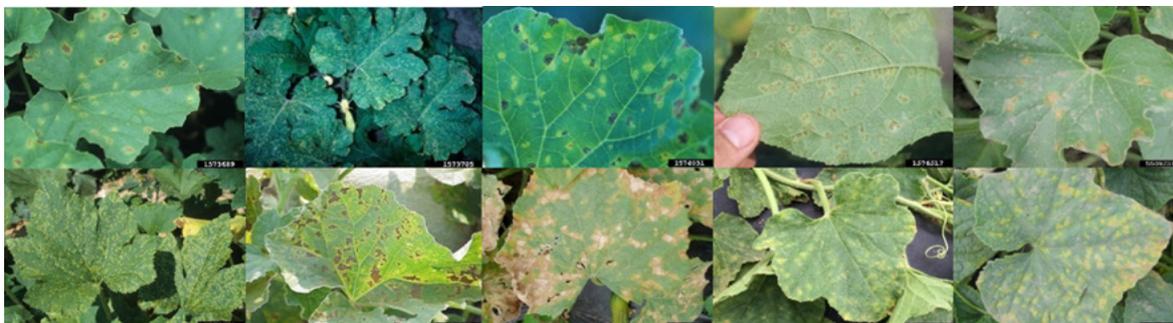


Figura 1. Imagens para testes da doença Peronospora.
Fonte: IPM Imagens. **Disponível em:** ipmimages.org. Acesso em: 20 ago. 2019.

Diplocarpon rosae (black spot)

Diplocarpon rosae é uma doença comum em várias espécies, mas sobretudo em rosas. Ela é causada por bactéria e grande quantidade de fungos. A doença costuma aparecer em clima úmido e sua característica principal são manchas pretas irregulares nas folhas, caule e partes da flor (ENCYCLOPAEDIA BRITANNICA, 2017). As dez imagens da Figura 2 apresentam a doença *Diplocarpon rosae* e foram utilizadas nos testes.



Figura 2. Imagens para testes da doença *Diplocarpon rosae*.
Fonte: IPM Imagens. **Disponível em:** ipmimages.org. Acesso em: 20 ago. 2019.

Oídio (powdery mildew)

Oídio é uma doença global, caracterizada por um crescimento pulverulento nas folhas, flores e frutos causado por um tipo de fungo. Sua aparência é de um pó branco que se espalha pelas folhas; com a evolução da doença, as folhas se tornam amareladas, distorcendo as próprias folhas e os frutos (ENCYCLOPAEDIA BRITANNICA, 2017).



Figura 3. Imagens para testes da doença Oídio.
Fonte: IPM Imagens. **Disponível em:** ipmimages.org. Acesso em: 20 ago. 2019.

Cancro cítrico

Cancro cítrico é uma doença que aparece como uma mancha na folha e uma espécie de ferida na casca do fruto; essas lesões, inicialmente, são pequenos pontos que podem chegar até o tamanho de 2 a 10 mm de diâmetro. As lesões ficam aparentes após sete dias da infecção e o sintoma mais aparente nas folhas é o halo amarelo ao redor da lesão (GORTWALD; GRAHAM, 2018).

As dez imagens da Figura 4 apresentam a doença Cancro cítrico e foram utilizadas para os testes e validações do aprendizado das três aplicações.



Figura 4. Imagens para testes da doença Cancro cítrico.
Fonte: IPM Imagens. **Disponível em:** ipmimages.org. Acesso em: 20 ago. 2019.

Aprendizado de máquina

O aprendizado de máquina é uma subárea da Inteligência Artificial (IA), utilizada também para reconhecimento de padrões e de regularidades nos dados analisados (BISHOP, 2006).

O treinamento utilizado é classificado como aprendizado supervisionado, os sistemas que se utilizam desta técnica podem ser treinados a partir de dados conhecidos, que são rotulados de acordo com o objetivo de classificação. O aprendizado supervisionado é a tarefa dentro do apren-

dizado de máquina de aprender uma função que mapeia uma entrada para uma saída com base em pares de entrada/saída de exemplo (MOHRI, 2012).

Após realizado o treinamento supervisionado, o conjunto de imagens deve ser validado com o objetivo de analisar se os padrões e as similaridades encontradas estão corretamente classificados de acordo com o rótulo ou etiqueta dada no treinamento. A validação pode ser realizada com o uso da técnica de *K-fold cross validation*, que serve para avaliar a capacidade de generalização de um modelo, a partir de um conjunto de dados (KOHAVI, 1995). Essa técnica é, em geral, utilizada em cenários nos quais o objetivo é a previsão, isto é, estimar quão preciso o modelo preditivo criado e treinado irá funcionar em um teste real. Neste caso, as imagens utilizadas para realizar o teste são as mesmas que foram utilizadas para o treinamento; a técnica consiste em dividir o conjunto total de dados e K subconjuntos de mesmo tamanho e exclusivos. Um desses subconjuntos é separado e utilizado para teste com os demais conjuntos K restantes — assim, é possível calcular a acurácia do modelo. O processo é repetido K vezes, tal que o subconjunto de teste é alterado de forma circular; por isso, a técnica também é conhecida como Estimativa de Rotação.

A acurácia dos dados pode ser validada por meio do modelo *Precision* e *Recall*, em que a funcionalidade *Precision* apresenta-se em forma de etiqueta. A etiqueta, por sua vez, será reconhecida pelo seu classificador, mostrando a probabilidade do conjunto de imagens estar correto na classificação, ou seja, de todas as imagens que foram utilizadas para treinar o classificador, qual a porcentagem que o modelo obteve de acerto, este é o que representa o *Precision*.

A funcionalidade *Recall* demonstra o valor encontrado das imagens que deveriam ter sido classificadas corretamente, comparado com quanto o identificador classificou corretamente (POWERS, 2007). Por exemplo, um *Recall* de 100% significa que de 38 imagens de animais utilizados para treinar, todas as 38 foram reconhecidas.

API I

O treinamento da API I inicia-se com a criação do domínio das imagens, em que cada domínio representa um contexto da imagem. Essa classificação prévia auxilia no treinamento da imagem, pois cada domínio oferecido pela ferramenta já possui um pré-treinamento da rede neural com o contexto do domínio.

O treinamento para as doenças apresentadas neste trabalho foi realizado com o domínio denominado “Genérico”. Neste modelo foram criadas quatro etiquetas (*tags* ou rótulos) — uma etiqueta para cada uma das doenças em estudo —, para agrupar imagens com características e padrões de similaridade. Cada etiqueta recebe um conjunto de imagens para treinamento e, posteriormente, podem ser adicionadas novas imagens à mesma etiqueta, a fim de melhorar a capacidade de identificação dos padrões do conjunto das imagens.

No modelo utilizado para a identificação das quatro doenças, com 30 imagens de treinamento, foram obtidas as médias 78,3% de *Precision* e 72,5% de *Recall*. Com 50 imagens, as médias tiveram pequeno acréscimo: 78,6% de *Precision* e 74,1% de *Recall*. O Quadro 1 apresenta os valores individuais obtidos para cada doença.

Doença	<i>Precision</i>	<i>Precision</i>	<i>Recall</i>	<i>Recall</i>
	30 imagens	50 imagens	30 imagens	50 imagens
1_downy_mildew	82,1 %	85,2 %	70,0 %	78,3 %
2_black_spot	73,8 %	82,6 %	66,7 %	70,2 %
3_powdery_mildew	83,2 %	76,6 %	76,7 %	86,0 %
4_citrus_canker	81,4 %	72,8 %	80,0 %	61,9 %

Quadro 1. Resultados dos treinamentos para cada doença com a API 1.

Esses valores foram obtidos utilizando um limite (*threshold*) de 50%, isto é, a ferramenta considerou apenas os valores nos quais a probabilidade de acerto encontrada foi maior que 50%.

API 2

Até o momento deste trabalho não havia uma interface para visualização do *Recall* e *Precision rate*. Então, não foi possível identificar os fatores de qualidade das imagens utilizadas para treinamento.

API 3

No treinamento realizado com a API 3 para as quatro doenças, com as 30 primeiras imagens, foram obtidas as médias 60,7% de *Precision* e 56,3% de *Recall*. Com 50 imagens de treinamento as médias foram 83,3%

de *Precision* e 76,7 de *Recall*. O Quadro 2 apresenta os valores individuais obtidos para cada doença.

Doença	Precision	Precision	Recall	Recall
	30 imagens	50 imagens	30 imagens	50 imagens
1_downy_mildew	100 %	100 %	75 %	66,7 %
2_black_spot	42,9 %	83,3 %	75 %	83,3 %
3_powdery_mildew	0 %	50,0 %	0 %	66,7 %
4_citrus_canker	100 %	100 %	75 %	90,0 %

Quadro 2. Resultados dos treinamentos para cada doença com a ferramenta 3.

Esses valores foram obtidos utilizando um limiar (*threshold*) de 50%: a ferramenta considerou apenas os valores em que a probabilidade de acerto encontrada foi maior que 50%.

Resultados

Os resultados dos testes das 3 APIs apresentam a probabilidade e medida em porcentagem de cada técnica em identificar a doença. O primeiro resultado destacado foram os erros obtidos por cada doença durante os treinamentos. O primeiro treinamento realizado utilizou 30 imagens e, o segundo treinamento, mais 20 imagens, totalizando 50. Foi considerado “erro” quando a técnica classifica uma doença de forma equivocada; a doença que apresentou maior quantidade de erros foi o Oídio, em relação à qual as três APIs classificaram a mesma imagem como *Peronospora* em vez de Oídio; porém, a API 3, após o segundo treinamento, obteve êxito no acerto da doença, com uma probabilidade de 40,4% de acerto, conforme a Figura 5.

Imagem	Treino	API 1				API 2				API 3			
		Probabilidade %				Probabilidade %				Probabilidade %			
		Peronospora	Oídio	Cancróctrico	Diplocarpon rosae	Peronospora	Oídio	Cancróctrico	Diplocarpon rosae	Peronospora	Oídio	Cancróctrico	Diplocarpon rosae
	Primeiro	92,6	0	0	0,3	87,6	13,9	0	0,1	3,6	89,7	0	9,7
	Segundo	92,6	0	0	0,3	41,4	78,5	0	0,1	4	92,8	0	2,5
	Primeiro	98,3	1,1	0	0	90,3	0,8	0	0,1	98,9	2,2	0,4	0
	Segundo	98,3	1,1	0	0	90,4	0,7	0	0	59,9	40,4	0,8	0

Figura 5. Erros na classificação oídio. Verde: aumento da probabilidade de identificação após segundo treinamento com 50 imagens. Vermelho: erro na identificação da doença. 2019.

Outro destaque foram os erros encontrados com a doença Peronospora. As três APIs classificaram de forma errada com o primeiro treinamento; mas, após o segundo, houve melhora nas classificações da API 2 (74,9%) e da API 3 (80,9%). A classificação da API 1 reteve a classificação errada, mantendo os mesmos valores.

Imagem	Treinos	API1				API2				API3			
		Probabilidade %				Probabilidade %				Probabilidade %			
		Peronospora	Oídio	Cancróctrico	Diplocarpon rosae	Peronospora	Oídio	Cancróctrico	Diplocarpon rosae	Peronospora	Oídio	Cancróctrico	Diplocarpon rosae
	Primeiro	32,6	9,4	1,0	0	89,5	5,6	0	0	98	0,01	0,01	0,0
	Segundo	32,7	9,4	1,0	0	83,7	5	0	0	98,6	2,4	1,0	0
	Primeiro	0	99,9	0,0	0	1,0	99,3	0	0,2	6,6	49,2	0	6,1
	Segundo	0	99,9	0	0	74,9	47,2	0,1	0,1	80,9	15,6	0	1,9

Figura 6. Erros na classificação Peronospora. Azul: diminuição da probabilidade na identificação após o segundo treinamento com 50 imagens.

Os erros encontrados para os dois treinamentos de acordo com cada doença e ferramentas podem ser vistos na Quadro 3.

	Downy Mildew			Black Spot		
	AP1	AP2	AP3	AP1	AP2	AP3
Treino 1	1	1	1	1	1	1
Treino 2	1	0	0	1	1	1
Total	2	1	1	2	2	2
	Powdery Mildew			Citrus Canker		
	AP1	AP2	AP3	AP1	AP2	AP3
Treino 1	2	2	1	1	1	0
Treino 2	2	1	1	0	0	0
Total	4	3	2	1	1	0

Quadro 3. Resultados dos erros por doença e ferramenta.

Após o segundo treinamento, observou-se uma melhora dos erros de classificação, como mostra o Quadro 4, que apresenta os valores consolidados e a diferença das quantidades de erros entre o primeiro treinamento e o segundo treinamento.

	AP1	AP2	AP3
Treino 1	5	5	3
Treino 2	4	2	2
Diferença	1	3	1

Quadro 4. Resultados dos erros consolidados e diferença de erros entre treinamentos.

Analisando as quantidades de acertos das técnicas na identificação da doença, os índices são próximos de 90% (nesta análise não foi considerado a acurácia na identificação, foi considerado apenas se a tecnologia obteve sucesso na identificação da doença contida na imagem e não seu grau de certeza no resultado apresentado. O Quadro 5 apresenta os valores dos acertos após os treinos.

	Downy Mildew			Black Spot		
	AP1	AP2	AP3	AP1	AP2	AP3
Treino 1	9	9	9	9	9	9
Treino 2	9	10	10	9	9	9
Total	9	9,5	9,5	9	9	9
	Powdery Mildew			Citrus Canker		
	AP1	AP2	AP3	AP1	AP2	AP3
Treino 1	8	8	9	9	9	10
Treino 2	8	9	9	10	10	10
Total	8	8,5	9	9,5	9,5	10

Quadro 5. Resultados dos acertos por doença e ferramenta.

Ao analisar os erros e acertos de cada tecnologia, é possível avaliar a precisão das técnicas na classificação das imagens de acordo com a doença contida na imagem. A análise mostra a porcentagem de probabilidade de a classificação estar correta (valores próximos de 100% indicam um alto índice de certeza).

O Quadro 6 apresenta as médias das probabilidades de acertos para cada doença, dividido entre os dois treinamentos e técnicas.

	Downy Mildew			Black Spot		
	AP1	AP2	AP3	AP1	AP2	AP3
Média Treino 1	77.74	79.94	85.79	75.22	82.03	82.31
Média Treino 2	77.89	88.32	93.63	75.22	78.2	81.44
Média Total	77.82	84.13	89.71	75.22	80.12	81.88
	Powdery Mildew			Citrus Canker		
	AP1	AP2	AP3	AP1	AP2	AP3
Média Treino 1	79.3	72.7	83.1	82.11	86.61	98.8
Média Treino 2	79.6	79.7	86.5	91.9	89.03	99.35
Média Total	79.46	76.21	84.76	87.01	87.82	99.08

Quadro 6. Média da probabilidade de acertos por doença, ferramenta e treino.

Conforme Wang *et al.* (2012), as CNNs (Redes Neurais Convolucionais) não precisam de muitos dados para o treinamento, afirmação comprovada nos resultados: com apenas 30 imagens foi possível atingir resultados de acerto acima de 70%. Vale ressaltar que os resultados melhoram a cada novo treinamento; porém, essa melhora só é possível quando realizado um treinamento com supervisão adequada (GÜLÇEHRE; BENGIO, 2016), nos quais os dados utilizados devem possuir relevância com o desafio.

Uma característica presente em duas das técnicas analisadas é a capacidade de ajustar a classificação de uma foto classificada erroneamente. Essa capacidade foi identificada nas APIs 2 e 3 e pode ser feita de maneira simples utilizando as APIs, ajustando a classificação da imagem para a etiqueta correta, utilizando uma das classificações previamente criadas ou criando uma nova classificação. Este tipo de correção permite corrigir o erro, propagando a correção para toda a rede por meio do conceito de retropropagação. Esta arquitetura, representada na Figura 7, faz com que a saída de uma camada seja utilizada como entrada para a próxima camada, e a função de ativação utilizada seja não linear; desta forma, funções complexas podem ser obtidas para mapeamento entre a entrada e a saída. Neste tipo de arquitetura, o treinamento é efetuado por retropropagação do erro obtido pela classificação. Assim, toda vez que um neurônio

é alterado, devido a uma classificação incorreta, ele irá propagar seu erro para os demais neurônios por meio de algoritmos de retropropagação ou regressão linear, fazendo com que toda a cadeia de neurônios tenha um novo aprendizado (PEDRINI; SCHWARTZ, 2008).

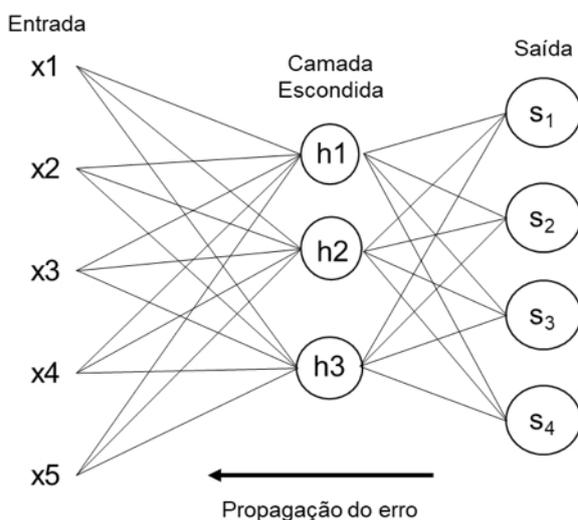


Figura 5. Arquitetura de rede neural multicamadas; treinamento utilizando retropropagação do erro (PEDRINI; SCHWARTZ, 2008).

Os resultados apresentados mostram que é possível utilizar ferramentas de visão computacional fornecida como APIs na identificação de doenças em plantas por meio de imagens; porém, são necessários maiores estudos para validação de dados. Uma possibilidade é aplicar as técnicas em campo, analisando imagens feitas diretamente em uma plantação e verificando seus acertos em condições distintas de luz, ângulo e fatores externos.

Referências

- ATZORI, Luigi; IERA, Antonio; MORABITO, Giacomo. The internet of things: a survey. *Computer Networks*, v. 54, n. 15, p. 2787-2805, 2010.
- BARBEDO, Jayme Garcia Arnal. Digital image processing techniques for detecting, quantifying and classifying plant diseases. *SpringerPlus*, v. 2, n. 1, p. 648-660, 2013.
- BISHOP, Christopher. *Pattern recognition and machine learning*. New York, Springer, 2006.
- ENCYCLOPAEDIA BRITANNICA. Powdery mildew. Chicago: Encyclopædia Britannica, 2017. Disponível em: britannica.com/science/powdery-mildew. Acesso em: 2 dez. 2017.

GONZALES, R. C; WOODS, R.E. *Processamento digital de imagens*. São Paulo: Blucher, 2000.

GOTTWALD, T. R; GRAHAM, James H. Citrus Canker. Site. Disponível em: apsnet.org/edcenter/intropp/lessons/prokaryotes/Pages/CitrusCanker.aspx. Acesso em: 14 fev. 2018.

GÜLÇEHRE, Ç.; BENGIO, Y. Knowledge matters: importance of prior information for optimization. *Journal of Machine Learning Research*, v. 17, n. 1, p. 226-257, 2016.

HANSEN, Karl D. *et al.* An autonomous robotic system for mapping weeds in fields. *IFAC Proceedings*, v. 46, n. 10, p. 217-224, 2013.

HARALICK, Robert M. *et al.* Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, n. 6, p. 610-621, 1973.

JUNTOLLI, Fabricio. Tecnologia já é usada em cerca de 67% das propriedades rurais do país. *Alimento Seguro*, Abril 17, 2017. Disponível em: alimentoseguro.com.br/post/159877367960/tecnologia-já-é-usada-em-cerca-de-67-das. Acesso em: 27 mai. 2017.

KAMLAPURKAR, Sushil R. Detection of plant leaf disease using image processing approach. *International Journal of Scientific and Research Publications*, v. 6, n. 2, p. 73-76, 2016.

KOHAVI, R. A study of cross-validation and bootstrap for accuracy estimation and model selection. *International joint conference on artificial intelligence*, v. 14, p. 1137-1145, 1995.

LUCAS, George B.; CAMPBELL, C. Lee; LUCAS, Leon T. *Introduction to plant diseases: Identification and management*. New York, NY: Springer, 1992.

MARQUES, F.O.; NETO, V. H. *Processamento digital de imagens*. Rio de Janeiro: Brasport, 1999.

MOHRI, Mehryar; ROSTAMIZADEH, Afshin; TALWALKAR, Ameet. *Foundations of machine learning*. Cambridge, MA: MIT Press, 2012.

PEDRINI, Hélio; SCHWARTZ, William Robson. *Análise de imagens digitais: princípios, algoritmos e aplicações*. São Paulo: Thomson Learning, 2008.

POWERS, David Martin. Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation. *Technical Report SIE 07-001*, 2007.

SANNAKKI, Sanjeev S. *et al.* Diagnosis and classification of grape leaf diseases using neural networks. In: *Computing, communications and networking technologies (ICCCNT), Fourth international conference*, p. 1-5, 2013.

VARGAS, Ana Caroline Gomes; PAES, Aline; VASCONCELOS, Cristina Nader. Um estudo sobre redes neurais convulsionais e sua aplicação em detecção de pedestres. In: *Proceedings of the XXIX conference on graphics, patterns and images*, p. 1-4, 2016.

WANG, T.; WU, D. J.; COATES, A.; NG, A. Y. End-to-end text recognition with convolutional neural networks. In: *International conference on pattern recognition (ICPR), 2012 21ST. IEEE*, p. 3304-3308, 2012.