

**PROGRAMA DE PÓS-GRADUAÇÃO EM PRODUÇÃO VEGETAL**

**Carmélia Maia Silva**

***Deep learning* na identificação e quantificação de flores de *Catharanthus roseus* (L.) G. Don**

**Montes Claros**

**2022**

**Carmélia Maia Silva**

***Deep learning* na identificação e quantificação de flores de *Catharanthus roseus* (L.) G. Don**

**Versão final**

Dissertação apresentada ao Programa de Pós-Graduação em Produção Vegetal da Universidade Federal de Minas Gerais, como requisito parcial para obtenção do título de Mestre em Produção Vegetal.

**Orientador:** Alcinei Místico Azevedo.

Montes Claros  
Fevereiro – 2022

Silva, Carmélia Maia.

S586d  
2022

*Deep learning* na identificação e quantificação de flores de *Catharanthus roseus* (L.) G. Don [manuscrito] / Carmélia Maia Silva. Montes Claros, 2022.  
63 f. : il.

Dissertação - Área de concentração em Produção Vegetal. Universidade Federal de Minas Gerais / Instituto de Ciências Agrárias.

Orientador(a): Alcinei Místico Azevedo.

Banca examinadora: Delacyr da Silva Brandão Junior, Elka Fabiana Aparecida Almeida, Leonardo Amaral Mozelli.

Inclui referências: f. 23-26; 40-41.

1. *Catharanthus* – Teses. 2. Arquitetura paisagística – Teses. 5. Jardins – Teses. I. Azevedo, Alcinei Místico. II. Universidade Federal de Minas Gerais. Instituto de Ciências Agrárias. III. Título.

CDU: 712

### ATA DE DEFESA DE DISSERTAÇÃO

Aos 22 dias do mês de fevereiro do ano de dois mil e vinte e dois, às 8:00 horas, sob a Presidência do Professor Alcinei Místico Azevedo, D. Sc. (Orientador – UFMG/ICA) e com a participação dos Professores Delacyr da Silva Brandão Júnior, D. Sc. (UFMG/ICA), Elka Fabiana Aparecida Almeida, D. Sc. (UFMG/ICA) e Leonardo Amaral Mozelli, D. Sc. (UFMG), reuniu-se, por videoconferência, a Banca de Defesa de Dissertação de **CARMÉLIA MAIA SILVA**, aluna do Curso de Mestrado em Produção Vegetal. Após avaliação da defesa de Dissertação da referida aluna, a Banca Examinadora procedeu à publicação do resultado da defesa de Dissertação intitulada: **“Deep learning na identificação e quantificação de flores de Catharanthus roseus (L.) G. Don”** sendo a aluna considerada **Aprovada**. E, para constar, eu, Professor Alcinei Místico Azevedo, Presidente da Banca, lavrei a presente ata que depois de lida e aprovada, será assinada por mim e pelos demais membros da Banca examinadora.


OBS.: A aluna somente receberá o título após cumprir as exigências do ARTIGO 68 do regulamento do Curso de Mestrado em Produção Vegetal, conforme apresentado a seguir:

**Art. 68 Para dar andamento ao processo de efetivação do grau obtido, o candidato deverá, após a aprovação de sua Dissertação ou Tese e da realização das modificações propostas pela banca examinadora, se houver, encaminhar à secretaria do Colegiado do Programa, com a anuência do orientador, no mínimo 3 (três) exemplares impressos e 1 (um) exemplar eletrônico da dissertação ou, 4 (quatro) exemplares impressos e 1 (um) exemplar eletrônico da tese, no prazo de 60 (sessenta) dias.**

Montes Claros, 22 de fevereiro de 2022.




Alcinei Místico Azevedo  
 Orientador



Elka Fabiana Aparecida Almeida  
 Membro



Delacyr da Silva Brandão Júnior  
 Membro



Leonardo Amaral Mozelli  
 Membro

## AGRADECIMENTOS

A Deus por toda força para a conquista dos meus objetivos.

Agradeço ao meu orientador Professor Alcinei Místico Azevedo, pela oportunidade da realização deste trabalho, pela confiança e ensinamentos.

Ao professor Delacyr pelo acolhimento e imprescindíveis ensinamentos dentro e fora da universidade.

Aos amigos que me ajudaram na obtenção das imagens, José Victor, Janete, Janine, Ellen e Ingrid, obrigada a cada um pelas conversas e pelo apoio de sempre.

Às minhas colegas e eternas amigas Bel, Kamila e Ingrid pelo companheirismo e parceria, mesmo à distância.

À minha família e, em especial, à minha irmã Cleidineia.

Ao meu namorado Divallo Félix pelo amor, carinho e paciência.

Às minha primas e amigas Isabela e Fernanda, vocês são as melhores!

Aos meus grupos de estudo: GEFLOP, SEMENTEC e GEEA pelo acolhimento e troca de conhecimento.

À banca examinadora que se dispôs a contribuir com o nosso trabalho.

À CAPES pelo auxílio financeiro durante o mestrado.

Aos funcionários e amigos do ICA-UFMG.

Por fim, agradeço a todos que de alguma forma contribuíram para a realização desta pesquisa.

Muito obrigada!

*“A vontade, considerada puramente em si mesma, é inconsciente; é uma simples tendência, cega e irresistível, a qual encontramos tanto na natureza do reino inorgânico e do vegetal e nas suas leis, como também na parte vegetativa da nossa vida: mas pelo acréscimo do mundo da representação que se desenvolveu pelo seu uso, ela adquire a consciência do seu querer e do objeto do seu querer; reconhece que aquilo que quer não é outra coisa senão o mundo e a vida como são; dizemos, por isso, que o mundo visível é a sua imagem ou a sua objetividade; e como o que a vontade quer é sempre a vida, pois que a vida para a representação é a manifestação da vontade, resulta que é indiferente e constitui puro pleonasma se em vez de dizer simplesmente “a vontade”, dissermos “a vontade de viver””.*

(SCHOPENHAUER, 2001)

## RESUMO

*Catharanthus roseus* (L.) G. Don conhecida popularmente como vinca, é uma espécie medicinal e ornamental. No paisagismo é uma opção para composição de jardins e apresenta floração em diversas cores. A Visão Computacional no setor da floricultura e paisagismo tem apresentado ferramentas para auxiliar no manejo, no cultivo e elaboração de projetos paisagísticos, como aplicativos para identificação de plantas. Desta forma, o objetivo deste trabalho foi avaliar o potencial da rede Mask R-CNN para quantificar flores de vinca e as qualificar quanto a cor para aplicação nos setores de floricultura e paisagismo. Foram coletadas 700 imagens, 500 apresentavam floração tanto rosa quanto branca e 200 apenas as folhas que compõem o *background*. Para composição do banco sintético de imagens 100 flores brancas e 100 flores rosas foram processadas em formato *png* e formaram o *foreground*, sendo as duas separadas como duas subclasses. O treinamento utilizando a técnica *transfer learning* com o algoritmo Mask R-CNN foi realizado no *Google colab*, com comandos em linguagem *python* e bibliotecas da plataforma Github. Por meio de avaliadores da qualidade de classificação, a rede neural convolucional Mask R-CNN apresentou precisão de 97% para a subclasse vinca rosa e 83% para a vinca branca, e acurácia geral acima de 80%. A rede se mostrou eficiente em estimar o número de flores, além de detectar e segmentar qualificando-as quanto à cor. Logo a metodologia pode ser utilizada na floricultura e paisagismo para estimar e quantificar flores por meio de imagens.

**Palavras-chave:** Vinca. Quantificação de flores. Visão Computacional. Mask R-CNN. Análise de imagem.

## ABSTRACT

*Catharanthus roseus* (L.) G. Don popularly known as vinca, is a medicinal and ornamental species, in landscaping it is an option for the composition of the garden, it has a flowering of different colors, in addition to be resistant to regions with a tropical climate. Computer vision in the landscape sector presented tools to help in the development and management of landscape projects such as applications for the identification of plants, but for the identification and quantification of flowers through images, there is still little information. Thus, the objective of this work was to evaluate the potential of the Mask R-CNN network to quantify vinca flowers and qualify them in terms of color for application in landscape projects. 700 images were collected, 500 had both pink and white flowers and 200 had just the leaves that made up the background. For the composition of the computer-generated image bank, 100 white flowers and 100 roses were processed in png format and formed the foreground, the two being separated into two subclasses. The training using the transfer learning technique with the Mask R-CNN algorithm was carried out in collaborative Google, with commands in python language and libraries from the github platform. Using quality raters, the Mask R-CNN convolutional neural network showed an accuracy of 97% for the pink vinca subclass and 83% for the white vinca subclass, and an overall accuracy greater than 80%. The network proved effective in estimating the number of flowers, in addition to detecting and segmenting them, qualifying them in terms of color. Therefore, the methodology can be used in landscaping to estimate and quantify flowers through images for garden composition.

**KEYWORDS:** Vinca. Quantification of flowers. Computer vision. Mask R-CNN. Image analysis.



## LISTA DE ILUSTRAÇÕES

1	INTRODUÇÃO.....	12
	Figura 1 – Flores da espécie <i>Catharanthus roseus</i> (L.) G. Don .....	12
	Figura 2 – Modelo de um neurônio artificial proposto por Warren McCulloch e Walter Pitts em 1943 .....	18
	Figura 3 – Modelo de uma Rede Neural – MLP com camadas intermediárias (neurônios intermediários) .. .....	19
	Figura 4 – Arquitetura de uma Rede Neural Convolutiva.....	20
	Figura 5 – Estrutura Mask R-CNN para segmentação de instâncias .....	22
5	ARTIGO .....	27
	Figura 1 – Banco sintético de imagens para o treinamento .....	30
	Figura 2 – Exemplo de imagens do banco sintético com imagens de <i>png</i> sobre o <i>background</i> (a) e sua respectiva máscara (b) obtida pela biblioteca <i>cocosynth</i> .....	30
	Figura 3 – Curvas da função de perda por iteração na classificação de flores de <i>Catharanthus roseus</i> (L.) G. Don. ....	34
	Figura 4 – Detecção e identificação da flor de vinca pela caixa delimitadora e máscara de segmentação.. .....	34
	Figura 5 – Estimativa do número de flores rosas e brancas (a) e do número de flores totais (b) em cada foto .....	36

## LISTA DE TABELAS

Tabela 1 – Parâmetros arbitrados para o ajuste de redes do tipo Mask R-CNN.....	31
Tabela 2 – Tabela de contingência.....	35
Tabela 3 – Valores referentes à precisão, recall, F-1, acurácia e especificidade avaliadas na classificação das flores de vinca nas cores rosa e branca.....	36

## LISTA DE ABREVIATURA E SIGLAS'

ICA	Instituto de Ciências Agrárias
CNN	Convolutional Neural Network
Mask R-CNN	Mask Region-based Convolutional Neural Network
RNA	Rede Neural Artificial
SSD	Single Shot Detector
UFMG	Universidade Federal de Minas Gerais
YOLO	You Only Look Once

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	12
<b>2</b>	<b>OBJETIVOS</b>	14
2.1	Objetivo Geral	14
2.2	Objetivos Específicos	14
<b>3</b>	<b>REVISÃO DE LITERATURA</b>	15
3.1	<i>Catharanthus roseus</i> (L.) G. Don	15
3.2	Floricultura	16
3.3	Paisagismo	16
3.4	Aplicação da análise de Imagem para identificação de flores	17
3.5	Redes Neurais Artificiais	18
3.6	Mask R-CNN	20
<b>4</b>	<b>REFERÊNCIAS</b>	23
<b>5</b>	<b>ARTIGO</b>	27
5.1	Artigo 1 – <i>Deep learning</i> na identificação e quantificação de flores de <i>Catharanthus roseus</i> (L.) G. Don	27
<b>6</b>	<b>CONSIDERAÇÕES FINAIS</b>	42

## 1 INTRODUÇÃO

*Catharanthus roseus* (L.) G. Don, conhecida popularmente como vinca, é uma planta ornamental espontânea e utilizada no paisagismo, é tolerante ao clima tropical, o que pode garantir beleza aos jardins durante todas as estações do ano (LORENZI; MATOS, 2008). As flores da vinca são vistosas e sua coloração pode variar de branca a rosa em tonalidades escuras e claras (NEJAT *et al.*, 2015).

Figura 1 – Flores da espécie *Catharanthus roseus* (L.) G. Don



Fonte: Da autora, 2022.

As flores são um dos principais elementos em uma composição paisagística, elas são importantes não apenas a esta finalidade, mas também são utilizadas em setores como a botânica e a farmacologia (DEMATTÊ, 2006). Identificar flores, classificá-las pela cor e quantificá-las automaticamente é um grande desafio desde seu cultivo por produtores até sua aplicação.

Alguns aplicativos para identificação de flores e plantas ornamentais utilizando Visão Computacional já foram desenvolvidos, mas nem sempre são eficientes para detectar as flores, em consequência principalmente da cor (FARIA *et al.*, 2020).

A Visão Computacional tem apresentado soluções para diversas tarefas, que quando realizadas pelo homem são demoradas e imprecisas (BACKES; SÁ JUNIOR, 2016). Com isso, a Visão Computacional tem se expandido e se tornado uma ferramenta útil no setor agrícola em tarefas como: detecção de diferentes níveis de danos causados por pragas e doenças perceptíveis em folhas, detecção de frutas, botões florais, e isso tem auxiliado no manejo da produção, assim como em outros setores. (MEUNKAEWJINDA *et al.*, 2008; LEE *et al.*, 2016).

Para a utilização da análise de imagem em espécies floríferas, uma opção é a Rede Neural Convolucional (CNN), que é um algoritmo de aprendizado profundo que captam imagens, atribuem características e conseguem diferenciá-las (HE *et al.*, 2017).

Entre os algoritmos que usam as Redes Neurais Convolucionais há a Mask R-CNN. Sua arquitetura de rede consegue identificar, detectar e segmentar diferentes objetos em imagens (HE *et al.*, 2017).

Desta forma, por meio das Redes Neurais Convolucionais do tipo Mask R-CNN pode ser possível quantificar flores de vinca, qualificando-as quanto à cor para aplicação em setores da floricultura e paisagismo.

## **2 OBJETIVOS**

### **2.1 Objetivo Geral**

Avaliar o potencial da rede Mask R-CNN para aplicação nos setores de floricultura e paisagismo para quantificar flores de vinca e as qualificar quanto à cor.

### **2.2 Objetivos Específicos**

- Verificar a aplicabilidade de redes do tipo Mask R-CNN na quantificação de flores de vinca;
- Verificar a aplicabilidade de redes do tipo Mask R-CNN na qualificação de flores de vinca quanto à cor.

### 3 REVISÃO DE LITERATURA

#### 3.1 *Catharanthus roseus* (L.) G. Don

*Catharanthus roseus* (L.) G. Don é uma planta medicinal e ornamental conhecida popularmente como vinca, vinca de Madagascar, pervinca e maria sem-vergonha (KOCH *et al.*, 2015). A espécie é uma dicotiledônea que pertence à família botânica das Apocynaceae, esta família compreende diversas espécies que também apresentam importância para muitas finalidades, desde potencial farmacológico ao amplo uso no paisagismo, pode-se citar como exemplo: rosa-do-deserto (*Adenium obesum*), alamanda (*Allamanda cathartica*) e a espirradeira (*Nerium oleander*) (LORENZI; MATOS, 2008; NIETSCHKE; ALMEIDA; MENDES, 2021; SANTOS *et al.*, 2022).

A vinca é originária da Ilha de Madagascar no continente Africano, é uma planta perene, subarborescente, podendo chegar a um metro de comprimento (LAHARE *et al.*, 2020). Suas folhas são de coloração verde escuro, opostas, inteiras e ovaladas, apresentam ápice arredondado e o tamanho que pode variar de cinco a nove centímetros de comprimento (LORENZI; MATOS, 2008).

De acordo com Lahare *et al.* (2020), as cultivares mais comuns de *Catharanthus roseus* são as que apresentam as flores rosadas denominadas de “Rósea”, onde se diferenciam entre rosa escuro e rosa claro. A outra cultivar é a que apresenta flores de coloração branca, sendo denominada de “Alba”. Apesar dessas duas diferenciações, ainda se encontram flores variegadas de rosa e branco. As flores em geral são solitárias ou geminadas, axilares com cinco pétalas e apresentam uma corola hipocrateriforme (LORENZI; MATOS, 2008). Os frutos são compostos com dois folículos deiscentes, as sementes são pequenas de cor preta e em grande número, a vagem pode chegar até três centímetros de comprimento, quando secas, a vagem se abre e as sementes são dispersas pelo vento (LORENZI; MATOS, 2008).

A espécie é explorada, por apresentar diversas propriedades utilizadas na medicina, como diurética, hipoglicemiante, anticâncer, antidiabética, cicatrizante, dentre outras propriedades biológicas (LAHARE *et al.*, 2020). Seus componentes principais são diversos alcaloides, dentre eles a vincristina e a vinblastina amplamente estudados, ainda em sua composição há a presença de muitos fenólicos e flavonoides e vem sendo largamente utilizada na medicina e farmacologia (LAHARE *et al.*, 2020).

A vinca é amplamente cultivada em países do continente africano, Índia, Austrália e alguns países da região europeia (LAHARE *et al.*, 2020). A espécie se espalhou por diversas regiões com clima tropical, no Brasil é utilizada principalmente no paisagismo, e sua ocorrência se dá de forma espontânea em diversos locais como praças, jardins, passeios e também de forma cultivada, pois suas flores são um grande atrativo para composições de jardins em pleno sol (LORENZI; MATOS, 2008).



### 3.2 Floricultura

A floricultura se apresenta como uma atividade intensiva que necessita de mão de obra constante e qualificada, esta atividade tem-se mostrado promissora dentro da horticultura. As atividades englobam desde a produção, cultivo de flores e plantas ornamentais, produção de folhagens, plantas em vasos, para corte e produção de mudas (NIETSCHÉ; ALMEIDA; MENDES, 2021). A produção resultante do setor da floricultura tem como finalidade a oferta de espécies e variedades diversificadas, que atendam ao desejo do consumidor, sempre apresentando novidades (JUNQUEIRA; PEETZ, 2011).

É um setor que apresenta grande rentabilidade em pequenas áreas cultivadas, devido as culturas possuírem ciclo curto, o retorno investido ocorre de maneira mais rápida (CLARO; OLIVEIRA, 1999). Segundo Oliveira e Brainer (2007), a região sudeste destaca-se como a mais produtora, mas a atividade se expande para outras regiões do país. O Brasil apresenta condições edafoclimáticas e extensão territorial para avanços no setor da floricultura, assim como tem buscado cada vez mais, mão de obra qualificada e tem investido em tecnologias que facilitam o manejo em campo das espécies (MARQUES, 2002). A produção do setor da floricultura atende diversas atividades em que as plantas ornamentais são fundamentais, como o paisagismo.

### 3.3 Paisagismo

O paisagismo é um conjunto de técnicas para elaboração de projetos de jardins, ele engloba arte e ciência na organização e transformação dos espaços, constituindo-os com plantas, adereços e até mesmo obras de arte (LIRA FILHO, 2002).

As plantas são essenciais para diversas áreas, fazem parte de nosso ecossistema natural e além de serem utilizadas no paisagismo são importantes na medicina farmacológica, nas produções agrícolas, são fonte de alimentos e constituem matas e florestas (OMER; HASAN; ANWER, 2020). Nas composições resultantes do paisagismo, observa-se que um dos principais focos é possibilitar que a vegetação esteja mais próxima do homem, e além de muitas folhagens, palmeiras e arbustos, as plantas com flores representam estimado valor ornamental e são um atrativo com diversos significados.

Isso ocorre porque as flores são um dos componentes mais chamativos do jardim, pois agregam beleza e imponência ao ambiente, principalmente devido à diversidade cores. As cores das flores podem atrair de forma visual, tanto pessoas como insetos e animais (OLIVEIRA; BRAINER, 2007). A cor é capaz de despertar a sensação visual que se dá a partir das luzes produzidas pelos diferentes comprimentos de ondas. As cores podem influenciar de forma eficiente a mente das pessoas, pois os comprimentos de onda de luz se correlacionam com determinadas cores e possuem a capacidade de separar os pigmentos específicos, que são encontrados na retina dos olhos, e são responsáveis pela visão de cores (LIRA FILHO, 2002). Esta separação de pigmentos pode ocorrer com maior ou menor intensidade, segundo o

comprimento de onda provocando diversas reações tanto físicas como psicológicas (SALVIATI, 1993).

Dessa forma, as composições constituídas pelas plantas ornamentais e em específicos suas cores, são um aspecto fundamental em um jardim, e as flores são um dos elementos mais efêmeros na expressão da cor (LIRA FILHO, 2002).

### **3.4 Aplicação da análise de imagem para identificação de flores**

Muitas ferramentas que englobam a Visão Computacional têm sido desenvolvidas e utilizadas para facilitar o manejo com as plantas ornamentais, seja tanto para pesquisa, produção, como nos projetos paisagísticos. Podemos citar, como exemplo, os aplicativos criados que contemplam bancos de dados e interfaces práticas para identificação de plantas, e muitas dessas identificações ocorrem principalmente por características como a flor e sua coloração, utilizando apenas a imagem pode-se classificar plantas quanto à espécie, família, gênero, dentre outras características (FARIA *et al.*, 2020).

De acordo com Lee *et al.* (2016), a classificação correta de plantas por meio de imagens é essencial para diversas áreas do conhecimento, como setor agrícola e, principalmente, para fins de proteção ao meio ambiente. Nem sempre é possível identificar uma espécie por meio apenas da folha, então torna-se necessário a interação com outros órgãos da planta como caule, frutos e flores.

A análise de imagem dentro da Visão Computacional pode ser uma ferramenta auxiliar nos setores da floricultura e paisagismo, da mesma forma que os aplicativos criados são eficientes para a botânica na identificação de plantas (LEE *et al.*, 2016). A identificação e a quantificação de flores para a floricultura e o paisagismo podem facilitar manejos com os jardins, como por exemplo: observar quanto a cobertura vegetal de uma espécie pode ser eficiente na forração de jardim, desde sua implantação até um completo estabelecimento da cultura naquele local, pode ser útil ainda para avaliar a quantidade de flores e folhas em campo, como até mesmo avaliar sua qualidade.

A utilização da análise de imagem tem crescido nos últimos anos, sendo uma ferramenta útil e não destrutível dos materiais vegetais, que possibilita a obtenção de dados de forma mais rápida e eficaz (WALTER; LIEBISCH; HUND, 2015).

Omer, Hasan e Anwer (2020) utilizaram a aplicação da análise de imagens para a identificação de flores de um conjunto de dados composto por 26 espécies. De acordo com os autores, a utilização das Redes Neurais Convolucionais apresentou resultados satisfatórios na detecção e diferenciação das flores por imagem, com uma precisão de 94,61%.

Muitos trabalhos contemplam a utilização de imagens para diferentes processos de manejo com flores, podemos citar: segmentação de imagens de flores de macieira Tian *et al.* (2020), detecção em tempo real de flores de três tipos de macieiras (WU *et al.*, 2020); detecção de inflorescências abertas e fechadas de videiras no início do desenvolvimento Pahalawatta *et*

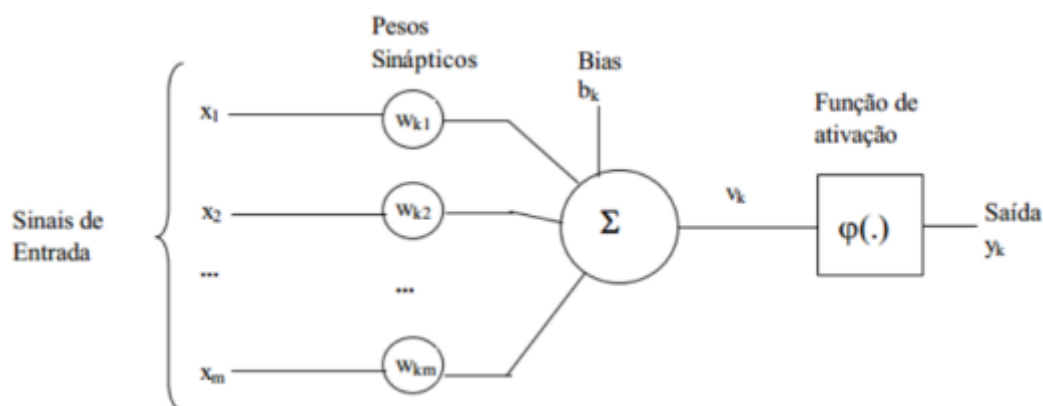
al., (2020). Detecção e classificação da área de lesões de doenças em plântulas da orquídea *Phalaenopsis*, utilizando o processamento de imagens (HUANG, 2007).

Pode-se observar que a análise de imagens, têm-se mostrado como uma ferramenta aliada e promissora em diversos setores agrônomicos, principalmente na identificação de diferentes estágios de flores seja para desbastes ou outros manejos relacionados à produtividade das culturas.

### 3.5 Redes Neurais Artificiais

As Redes Neurais Artificiais (RNAs) são modelos computacionais que se inspiram no sistema nervoso biológico. São uma série de unidades de processamento paralelo e são constituídas por neurônios artificiais, ou seja, neurônios não biológicos que processam dados e informações por pesos sinápticos, como pode ser observada na Figura 2, o modelo proposto por Warren McCulloch e Walter Pitts. As RNAs são associadas por um vasto número de interconexões, determinam funções matemáticas, sendo na maioria das vezes não linear e seu comportamento ocorre devido às interações entre as unidades de processamento da rede (BRAGA; CARVALHO; LUDEMIR, 2000; DA SILVA; SPATTI; FLAUZINO, 2016).


Figura 2 – Modelo de um neurônio artificial proposto por Warren McCulloch e Walter Pitts em 1943



Fonte: HAYKIN, 2009.

As Redes Neurais Artificiais possuem distintas classes, dentre elas as Perceptrons de Múltiplas Camadas são comumente utilizadas pela facilidade que apresentam. As MLP (*Multilayer perceptron*), são um tipo de rede que possuem camadas de neurônios intermediários. A seguir tem-se o exemplo de uma Rede Neural Artificial de múltiplas camadas (RUSSEL; NORVIG, 2016). No exemplo da Figura 3, tem-se uma Rede Neural Artificial composta por duas camadas, quatro entradas e duas saídas. Pode-se entender que as entradas simulam a captação de estímulos, os pesos equivalem-se as sinapses, os neurônios se referem as saídas e a partir de muitos neurônios obtém-se uma RNA.

Figura 3 – Modelo de uma Rede Neural – MLP com camadas intermediárias (neurônios intermediários)



Fonte: UFPE, 2022.

De acordo com Ruggiero *et al.* (2003), as redes neurais veem sendo recorrentemente utilizadas nos manejos da agricultura, desde a análise de dados referentes a pragas, doenças, floração, produtividade e até mesmo a observação de dados de ordem climatológica. O investimento na agricultura de precisão tem aumentado, pois facilita a obtenção de dados e informações de maneira eficiente, e é adaptável a diversos processos superando tarefas manuais (HAYKIN, 2001).

Diversos trabalhos têm demonstrado o interesse em incrementar a utilização das Redes Neurais Artificiais em seus processos. No nordeste do Brasil, as redes neurais artificiais têm sido aplicadas para a obtenção de informações de cunho meteorológico, na obtenção de dados de temperaturas, e isso tem substituído as informações que eram advindas de equações matemáticas encontradas na literatura (MOREIRA; CECÍLIO, 2008).

Na cultura do milho, Resende e Oliveira (2005) incluíram a Rede Neural Artificial como uma ferramenta para obtenção de dados de evapotranspiração com referências diárias, o que facilita o manejo relacionado à irrigação, os autores consideram sucesso com a utilização da ferramenta, já que saberão quanto a cultura perde de água e quanto ela necessita no momento da irrigação.

No melhoramento genético, as Redes Neurais Artificiais atuam principalmente em relação à divergência genética de espécies vegetais. Segundo Plotze (2004), padrões de agrupamentos nas plantas são facilmente reconhecidos com a utilização das redes neurais.

Em áreas de produção de café, Vieira, Lacerda e Botelho (2009), por meio das redes neurais artificiais treinadas, conseguiram definir procedimentos de classificação automática, na identificação de imagens por satélite de áreas cafeeiras, com as informações obtidas foram feitas classificações de uso da terra.

As redes neurais têm se tornado ferramentas essenciais em muitas áreas, e a Rede Neural Convolutiva (CNN) é uma das redes mais utilizadas para identificação, detecção de objetos, classificação e segmentação de imagens (KHAN *et al.*, 2020). A Mask R-CNN dentro das Redes Neurais se tornou uma das mais requisitadas para a análise de imagens. Em

diversas pesquisas evidencia-se o quão eficiente ela é na resolução e reconhecimentos de diferentes objetos em imagens (LIU *et al.*, 2017).

Tem auxiliado na fenotipagem de plantas (TODA *et al.*, 2020), segmentação de plantas daninhas (MORA-FALLAS *et al.*, 2020), dentre outros trabalhos que a descrevem como uma das redes que apresentam elevados valores referentes à precisão.

### 3.6 Mask R-CNN

As Redes Neurais Convolucionais (*Convolutional Neural Network - CNN*), são um modelo especial das redes neurais de aprendizado profundo (*Deep Learning*), aprimoradas no aparato que combina a percepção do campo de visão a exemplo dos seres vivos, onde a arquitetura hierárquica de uma estrutura que apresenta uma percepção simples pode funcionar de forma complexa (HUBEL; WIESEL, 1968).

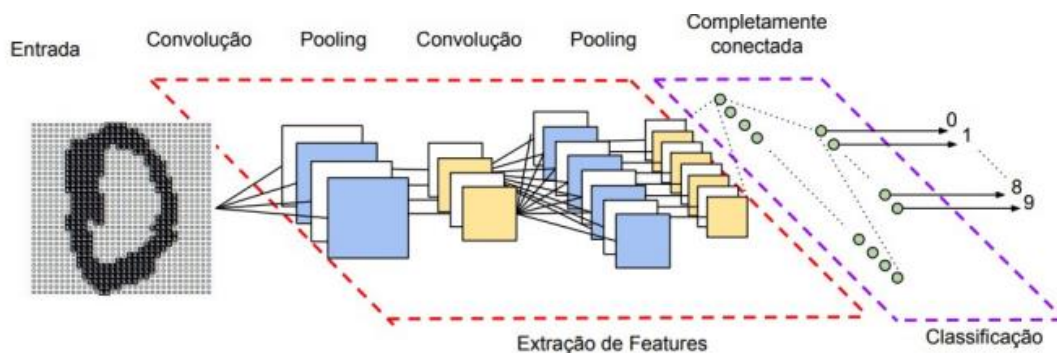
A composição básica de uma CNN pode ser estruturada da seguinte forma: A camada de convolução, composta por filtros e que podem ser denominados como *Kernels* empregues a imagem de entrada (LI; KARPATY; JOHNSON, 2016).

A camada de *pooling* que diminui a dimensão dos mapas de características, levando em conta a semelhança de valores vizinhos, a camada de *pooling* diminui a camada anterior (LI; KARPATY; JOHNSON, 2016). E por fim, as *Fully Connected Layers* - Camadas totalmente conectadas, nesta, cada nó de uma camada é similar ao nó de outra camada e assim todas estão conectadas a camada posterior (LI; KARPATY; JOHNSON, 2016).

Os atributos coletados previamente pelas camadas de convolução e pela camada de *pooling* serão utilizadas como entradas para as camadas totalmente conectadas, que irão interpretar os atributos de alto nível de abstração e serão responsáveis por realizar operações com o cunho mais complexo, pode-se entender como exemplo: a classificação de objetos (YOSINSKI *et al.*, 2014).

Logo após as camadas totalmente conectadas tem-se a camada de saída, o tamanho da camada será semelhante ao número de classes do problema, e a saída é o resultado da convolução (YOSINSKI *et al.*, 2014).

Figura 4 – Arquitetura de uma Rede Neural Convolutional



A detecção de objetos a partir da CNN pode ser compreendida em duas etapas, a primeira pode ser definida como classificação, nesta etapa ocorre a associação de um ou mais objeto a classes, a segunda etapa é a localização, quando se obtém as coordenadas dos pontos que determinam um retângulo circunscrito aos objetos de interesse, dá-se o nome de *bounding boxes* (FELZENSZWALB *et al.*, 2010).

A classificação da imagem pode ser feita pelos classificadores binários ou pelas camadas totalmente conectadas de uma Rede Neural Convolutiva, em que a camada de saída apresentará as probabilidades da imagem pertencer a cada uma das classes possíveis, no entanto a classe de saída que terá a maior probabilidade é determinada como a classe do objeto (GIRSHICK *et al.*, 2014).

Dentre os algoritmos utilizados para a detecção de objetos podemos citar algumas das arquiteturas de Rede Neural Convolutiva, como a *Faster R-CNN*, proveniente da *Region Proposal Network* – RPN e da *Fast R-CNN*. Sendo a *Faster* mais eficiente que a *Fast R-CNN* pois, por meio das RPN consegue propor caixas delimitadoras sobre os objetos, e tem-se um melhor resultado em relação ao desempenho da detecção dos objetos nas imagens (REN *et al.*, 2015).

Outra arquitetura utilizada para detecção de objetos é a *You Only Look Once* – YOLO. A YOLO possui a capacidade de prever sobre os objetos detectados nas imagens uma caixa delimitadora e a possibilidade de ter a classe presente na imagem, ocorrendo todo esse processo em apenas uma rede neural (REDMON *et al.*, 2016). É comumente utilizada para detecção de objetos em tempo real, mas sua desvantagem em relação a arquiteturas como a *Faster R-CNN* é que apresenta um maior número de erros na localização (REDMON *et al.*, 2016).


Semelhante ao YOLO tem-se o detector *Single Shot Detector* – SSD, que pode ser utilizado para detecção de imagens em tempo real, assim como o YOLO passa pela imagem uma única vez, o SSD apresenta um total de 59 fps o que corresponde, no entanto, a muitos quadros. O SSD demonstra resultados mais precisos e rápidos em comparação com as arquiteturas citadas anteriormente, pois não utiliza nas detecções das imagens a região proposta de interesse, o SSD durante seu processo iniciasse em caixas padrões que apresentam um tamanho que não muda em diferentes escalas (LIU *et al.*, 2017).

Por fim, tem-se uma arquitetura de rede que funciona de forma relativamente precisa quanto a SSD, a *Mask R-CNN*. Inspirada na *Faster R-CNN*, a rede neural convolutiva regional de máscara, apesar de sua precisão funciona de forma lenta e inviabiliza a utilização em tempo real (HE *et al.*, 2017).

A *Mask R-CNN* é uma arquitetura que consegue fazer detecção de muitos objetos na imagem, realiza a segmentação com a utilização de uma máscara sobre o objeto, fazendo a segmentação semântica de acordo com a classe definida e realiza também a segmentação de instâncias, que classifica de forma separada cada objeto atribuindo a eles diferentes cores, como pode ser observada na figura 5 (HE *et al.*, 2017). No entanto, a finalidade da *Mask R-*

CNN é gerar caixas delimitadoras (*bounding boxes*), classificar e segmentar objetos identificados nas imagens.

Figura 5 – Estrutura Mask R-CNN para segmentação de instâncias



Fonte: HE *et al.*, 2017.

A Mask R-CNN é uma estrutura de rede neural que realiza processamento de imagens, e uma de suas finalidades mais utilizadas é para detectar instâncias e segmentar objetos, pois a rede se mostra eficiente e precisa (PAHALAWATTA *et al.*, 2020).

Para Liu *et al.* (2017), a utilização das redes neurais convolucionais de aprendizado profundo, vem se tornando uma ferramenta de uso comum, pois elas conseguem demonstrar bons resultados na identificação de objetos nas análises de imagens. O método de aprendizagem profunda contribui de maneira significativa para classificação, segmentação de imagens e detecção de diversos tipos de objetos (OMER; HASAN; ANWER, 2020).

#### 4 REFERÊNCIAS

- BRAGA, A. P.; CARVALHO A. P. L. F.; LUDEMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro: LTC, 2000. 262p.
- BACKES, A. R. SÁ JUNIOR, J. J. M. **Introdução da visão computacional usando MATLAB**. Rio de Janeiro: Alta books, 2016.
- CLARO, D. P.; OLIVEIRA, P. B. de. A comercialização de flores na Ceasa / Campinas e no Veiling Holambra. **Revista Brasileira Horticultura Ornamental**, Campinas, v. 5, n. 1, p 70-77, 1999.
- DA SILVA, I. N.; SPATTI, D.; FLAUZINO, R. **Redes neurais artificiais: para engenharia e ciências aplicadas**. 2. ed. São Paulo: Artliber, 2016. Disponível em: [https://artliber.com.br/amostra/redes\\_neurais.pdf](https://artliber.com.br/amostra/redes_neurais.pdf). Acesso em: 25 jan. 2022.
- DEMATTÊ, M. E. S. P. **Princípios de paisagismo**. 3. ed. Jaboticabal: FUNEP, 2006. 143 p.
- FARIA, G.H. C.; CORREA, S. D.; VAZ, C.E.V.; NASCIMENTO, E. C. O uso de mídias móveis aplicado ao ensino aprendizagem de paisagismo. **Arquitetura Revista**, v.16, n. 2, jul./dez. 2020.
- FELZENSZWALB, P. F.; GIRSHICK, R. B.; MCALLESTER, D.; RAMANAN, D. Object detection with discriminatively trained part-based models. **IEEE transactions on pattern analysis and machine intelligence**, v. 32, n. 9, p. 1627–1645, 2010.
- GIRSHICK, R.; DONAHUE, J.; DARRELL, T.; MALIK, J. Rich feature hierarchies for accurate object detection and semantic segmentation. *In: IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, 2014, [s.l.]. Proceedings [...]. [S.l.], 2014. p. 580–587.* Disponível em: <https://ieeexplore.ieee.org/document/6909475>. Acesso em: 25 jan. 2022.
- HAYKIN, S. **Redes neurais: princípios e prática**. Porto Alegre: Bookman, 2001. 900 p.
- HAYKIN, S. S. **Neural networks and learning machines**. 3<sup>rd</sup> ed. [New Jersey]: Pearson, 2009.
- HE, K.; GKIOXARI, G.; DOLLÁR, P.; GIRSHICK, R. Mask r-cnn. *In: IEEE INTERNATIONAL CONFERENCE ON COMPUTER VISION, 2017, [s. l.]. Proceedings [...]. [S. l.], 2017. p. 2961-2969.*
- HUANG, K. Y. Application of artificial neural network for detecting *Phalaenopsis* seedling diseases using color and texture features. **Computers and Electronics in Agriculture**, v. 57, n. 1, p. 3–11, maio 2007.
- HUBEL, D. H.; WIESEL, T. N. Receptive fields and functional architecture of monkey striate cortex. **The Journal of Physiology**, v. 195, n. 1, p. 215–243, mar. 1968. ISSN 0022-3751.
- JUNQUEIRA, A. H.; PEETZ, M. S. Panorama Socioeconômico da floricultura no Brasil. **Revista Brasileira de Horticultura Ornamental**, v. 17, n. 2, p. 101 – 108, 2011.
- KHAN, A.; SOHAIL, A.; ZAHOORA, U.; QURESHI, A. S. A survey of the recent architectures of deep convolutional neural networks. **Artificial Intelligence Review**, v. 53, n. 8, p. 5455–5516, 2020. DOI: 10.1007/s10462-020-09825-6.
- KOCH, I.; RAPINI, A.; SIMÕES, A. O.; KINOSHITA, L. S.; SPINA, A. P.; CASTELLO, A. C. D. *Apocynaceae*. *In: Lista de espécies da flora do Brasil*. Rio de Janeiro: Jardim Botânico do Rio de Janeiro, 2015. Disponível em: <http://floradobrasil.jbrj.gov.br/jabot/floradobrasil/FB117227>. Acesso em: 22 nov. 2021.



LAHARE, R. P.; YADAV, H. S.; DASHAHRE, A. K.; BISEN, Y. K. An Updated Review on Phytochemical and pharmacological properties of *Catharanthus rosea*. **Saudi Journal of Medical and Pharmaceutical Sciences**, Dubai, 2020. DOI: 10.36348/sjimps.2020.v06i12.007. Acesso em: 22 nov. 2021.

LEE, S. H.; CHANG, Y. L.; CHAN, C.S.; REMAGNINO, P. Plant identification system based on a convolutional neural network for the lifeclef. **Plant Classification Task**, 2016. Disponível em: <http://ceur-ws.org/Vol-1609/16090502.pdf>. Acesso em: 28 out. 2021.

LI, F. F.; KARPATY, J.; JOHNSON, J. Cs231n convolutional neural networks for visual recognition. **Neural networks**, v. 1, 2016. Disponível em: <https://cs231n.github.io/convolutional-networks>. Acesso em: 4 set. 2021.

LIRA FILHO, J. A. **Paisagismo**: elementos de composição e estética. Viçosa: Aprenda Fácil, 194, 2002. (Coleção jardinagem e paisagismo; Série planejamento paisagísticos, 2). p. 9.

LIU, W.; WANG, Z.; LIU, X.; ZENG, N.; LIU, Y.; ALSAADI, F. E. A survey of deep neural network architectures and their applications. **Neurocomputing**, v. 234, p. 11-26. 2017.

LORENZI, H.; MATOS, F. J. de A. **Plantas Medicinais no Brasil**: nativas e exóticas. 2 ed. Nova Odessa: Instituto Plantarum, 2008.

MARQUES, R. W.C. **Avaliação da sazonalidade do mercado de flores e plantas ornamentais do estado de São Paulo**. 2002. 114f. Dissertação (Mestrado em Ciências-Economia Aplicada) – Escola Superior de Agronomia Luiz de Queiroz, Universidade de São Paulo, Piracicaba, 2002.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, v. 5, p. 115–133, 1943. DOI: <https://doi.org/10.1007/BF02478259>.

MEUNKAEWJINDA, A.; KUMSAWAT, P.; ATTAKITMONGCOL, K.; SRIKAEW, A. Grape leaf disease detection from color imagery using hybrid intelligent system; Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology, 2008. ECTI-CON 2008. *In*: INTERNATIONAL CONFERENCE, 5., 2008, [s.l.]. **Proceedings [...]**. [S.l.], v. 1, p. 513 – 516, 14-17 Maio 2008.

MORA-FALLAS, H.; GOËAU, A.; JOLY, A.; BONNET, P.; MATA-MONTEIRO, E. Instance segmentation for automated weeds and crops detection in farmlands. Tecnología en marcha, Edición especial 2020. *In*: LATIN AMERICA HIGH PERFORMANCE COMPUTING CONFERENCE (CARLA), 6., 2020, [s.l.]. **Proceedings [...]**. [S.l.], 2020. Disponível em: <https://agritrop.cirad.fr/595850/1/595850.pdf>. Acesso em: 30 out. 2021.

MOREIRA, M. C.; CECÍLIO, R. A. Estimativa das temperaturas do ar utilizando redes neurais artificiais, para a região Nordeste do Brasil. **Revista Brasileira de Agrometeorologia**, v. 16, n. 2, p. 181-188, 2008.

NEJAT, N.; VALDIANI, A.; CAHILL, D.; TAN, Y-H.; MAZIAH, M.; ABIRI, R. "Ornamental Exterior versus Therapeutic Interior of Madagascar Periwinkle (*Catharanthus roseus*): the two faces of a versatile herb". **The Scientific World Journal**, 2015. 19 p. DOI: <https://doi.org/10.1155/2015/982412>. Acesso em: 2 abr. 2022.

NIETSCHE, S.; ALMEIDA, E. F. A.; MENDES, R. B. **Cultivo e Manejo da Rosa-do-Deserto**. São José dos Pinhais: Brazilian Journals, 2021. 187 p.

OLIVEIRA, A. A. P.; BRAINER, M. S. C. P. **Floricultura**: caracterização e mercado. Fortaleza: Banco do Nordeste do Brasil, 2007. (Série Documentos do ETENE, n. 16). 180 p.

OMER, S. M.; HASAN, R. M.; ANWER, B. N. An image dataset construction for flower recognition using convolutional neural network. **Science journal of university of Zacho**, v. 8, n. 3, p. 112-117, Sept. 2020.

PAHALAWATTA, K.; FOURIE, J.; PARKER, A.; CAREY, P.; WERNER, A. Detection and classification of opened and closed flowers in grape inflorescences using Mask R-CNN. University of Canberra. *In*: INTERNATIONAL CONFERENCE ON IMAGE AND VISION COMPUTING NEW ZEALAND (IVCNZ), 35., 2020, [s.l.]. **Proceedings [...]**. [S.l.], 2021. p. 1-6. DOI: 10.1109/IVCNZ51579.2020.9290720.

PLOTZE, R. O. **Identificação de espécies vegetais através da análise da forma interna de órgãos foliares**. 2004. 152f. Dissertação (Mestrado em Ciências de Computação e Matemática Computacional) - Universidade de São Paulo, Instituto de Ciências Matemáticas e de Computação, São Paulo, 2004.

REDMON, J.; DIVVALA, S.; GIRSHICK, R.; FARHADI, A. You only look once: unified, real-time object detection. *In*: IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, 2016, [s. l.]. **Proceedings [...]**. [S. l.], p. 779–788, 2016.

REN, S.; HE, K.; GIRSHICK, R.; SUN, J. Faster r-cnn: Towards real-time object detection with region proposal networks. *In*: ADVANCES IN NEURAL INFORMATION PROCESSING SYSTEMS, 2015, [s. l.]. **Proceedings [...]**. [S. l.], p. 91–99, 2015.

RESENDE, M.; OLIVEIRA, A. C. Comparação de diferentes estratégias de programação de irrigação suplementar em milho. **Revista Brasileira de Milho e Sorgo**, v. 4, n. 2, 2005. DOI: 10.18512/1980-6477/rbms.v4n02p%25p.

RUGGIERO, C.; DURIGAN, J. F.; GOES, A. de; NATALE, W.; BENASSI, A. C. Panorama da cultura do mamão no Brasil e no mundo: situação atual e tendências. *In*: MARTINS, D. dos S. (ed.). **Papaya Brasil: qualidade do mamão para o mercado interno**. Vitória: Incaper, 2003. p. 13-34

RUSSELL, S. J.; NORVIG, P. **Artificial intelligence: a modern approach**. Malasya: Pearson Education Limited, 2016.

SALVIATI, E. J. Tipos vegetais aplicados no paisagismo. **Paisagem e Ambiente**, v. 5, p. 9-45, 1993. DOI: 10.11606/issn.2359-5361.v0i5p9-45.

SANTOS, A. F. dos; SANTOS, L. T. dos; NASCIMENTO, M. P. do; OLIVEIRA, E. L. de; RIBEIRO, T. G.; PEREIRA, F. D.; LIMA, G. de A.; GONÇALVES, W. T.; ROCHA, M. I.; FEITOSA, T. K. M.; CRUZ, M. F. da; TAVARES, S. G. S.; FIGUEROA, M. E. V.; PEREIRA, G. G. Review of three medicinal and ornamental species of the family Apocynaceae Juss. **Research, Society and Development**, [S. l.], v. 11, n. 2, p. e1011224876, 2022. DOI: 10.33448/rsd-v11i2.24876.

SCHOPENHAUER, A. **O mundo como vontade e representação**. Tradução de M. F. Sá Correia. Rio de Janeiro: Contraponto, 2001.

TIAN, Y.; YANG, G.; WANG, Z.; LI, E.; LIANG, Z. Instance segmentation of apple flowers using the improvised mask R-CNN model. **Biosystems engineering**, v. 193, p. 264-278, 2020.

TODA, Y.; OKURA, F.; ITO, J.; OKADA, S.; KINOSHITA, T.; SAISHO, D. Training instance segmentation neural network with synthetic datasets for crop seed phenotyping. **Communications Biology**, v. 3, n. 173, Apr. 2020. Disponível em: <https://www.nature.com/articles/s42003-020-0905-5>. Acesso em: 30 out. 2021.

UNIVERSIDADE FEDERAL DE PERNAMBUCO – UFPE. Centro de Informática da UFPE: há mais de 45 anos inovando e empreendendo. *In*: **Centro de Informática UFPE**. Recife: UFPE, 2022. Disponível em: <https://www.cin.ufpe.br>. Acesso em: 5 jan. 2022.

VARGAS, A. C. G.; PAES, A.; VASCONCELOS, C. N. Um estudo sobre redes neurais convolucionais e sua aplicação em detecção de pedestres. *In*: CONFERENCE ON GRAPHICS, 29., Patterns and Images, 2016, Niterói. **Proceedings** [...]. Niterói, 2016. p. 1-4.

VIEIRA, T. G. C.; LACERDA, W. S.; BOTELHO, T.G. Mapeamento de áreas cafeeiras utilizando redes neurais artificiais: Estudo de caso na região de Três Pontas, Minas Gerais. Anais Simpósio Brasileiro de Sensoriamento Remoto, 14., 2009, Natal, Brasil. **Anais** [...]. Natal, 25-30 abr. 2009, INPE, p. 7947-7954.

WALTER, A.; LIEBISCH, F.; HUND, A. Plant phenotyping: from bean weighing to image analysis. **Plant Methods**, v.11, p.14, 2015. Disponível em: <https://plantmethods.biomedcentral.com/track/pdf/10.1186/s13007-015-0056-8.pdf>. Acesso em: 23 Sept. 2021.

WU, D.; LV, S.; JIANG, M.; SONG, H. Using channel pruning-based YOLO v4 deep learning algorithm for the real-time and accurate detection of apple flowers in natural environments. **Computers and electronics in agriculture**, v. 178, Nov. 2020.

YOSINSKI, J.; CLUNE, J.; BENGIO, Y.; LIPSON, H. How transferable are features in deep neural networks? **Advances in Neural Information Processing Systems**, v. 27, p. 3320-3328, Dec. 2014. Disponível em: <https://arxiv.org/pdf/1411.1792.pdf>. Acesso em: 18 out. 2021.

## 5 ARTIGO

### 5.1 Artigo 1 – *Deep learning* na identificação e quantificação de flores de *Catharanthus roseus* (L.) G. Don

Este artigo foi elaborado conforme as normas do Programa de Pós-Graduação em Produção Vegetal.

#### RESUMO

As técnicas de *deep learning* vem cada vez mais automatizando tarefas realizadas manualmente, isso graças a robustez e precisão de seus resultados, o que incita sua utilização como ferramenta no setor da floricultura e paisagismo. O paisagismo engloba técnicas para construção de projetos com foco na criação de jardins, um dos atrativos nestas composições são as flores. A quantidade de espécies florísticas é ampla e vasta, seja em formato, textura e cor. A espécie ornamental *Catharanthus roseus* considerada de clima tropical apresenta cultivares em que a coloração das flores é um de seus aspectos atrativos, e estas flores podem variar de brancas a diferentes tons de rosa. Desta forma, o objetivo deste trabalho foi utilizar as técnicas de aprendizado profundo para avaliar o potencial da rede Mask R-CNN para quantificar flores de vinca e as qualificar quanto à cor para aplicação nos setores de floricultura e paisagismo. Foram coletadas em jardins do Norte de Minas por meio de câmeras de *smartphones*, 700 imagens, 500 apresentavam floração tanto rosa quanto branca e 200 apenas as folhas que compõem o *background*. Para composição do banco sintético de imagens, 100 flores brancas e 100 flores rosas foram processadas em formato png e formaram o *foreground*, sendo as duas separadas como duas subclasses. O treinamento utilizando a técnica *transfer learning* com o algoritmo Mask R-CNN foi realizado no *Google colaboratory*, com comandos em linguagem *python* e bibliotecas da plataforma Github. Por meio de avaliadores da qualidade de classificação, a Rede Neural Convolutiva Mask R-CNN apresentou precisão geral acima de 90% e acurácia acima de 80%. A rede se mostrou eficiente em estimar o número de flores, além de detectar e segmentar qualificando-as quanto à cor. Logo, a metodologia pode ser utilizada no setor da floricultura e paisagismo para estimar e quantificar flores por meio de imagens.

**Palavras-chave:** Análise de imagem. Floricultura. Paisagismo. Mask R-CNN. Redes Neurais Convolucionais.

#### ABSTRACT

Deep learning techniques are increasingly automating tasks performed manually, thanks to the robustness and precision of their results, which encourages their use as a tool in the floriculture and landscaping sector. The amount of floristic species is wide and diverse, whether in shape, texture or color. The ornamental species *Catharanthus roseus*, considered to have a tropical climate, it has cultivars in which the color of the flowers is one of its attractive aspects, and these can vary from white to different shades of pink. Thus, the objective of this work was to use deep learning techniques to evaluate the potential of the two-stage convolutional approach called Mask R-CNN to quantify *C. roseus* flowers and qualify them in terms of color for application in

the floriculture and landscaping sectors. 700 images were collected in gardens in the North of Minas through smartphone cameras, of which 500 had both pink and white flowering and 200 had only the leaves, to compose the *background*. For the composition of the synthetic image bank, 100 white flowers and 100 pink flowers were processed in png format and formed the foreground, the two being separated as two subclasses. The training using the transfer learning technique with the Mask R-CNN algorithm was carried out in Google collaborative, with commands in python language and libraries from the Github platform. Through rating quality evaluators, the Convolutional Neural Network Mask R-CNN showed overall accuracy above 90% and accuracy above 80%. The network proved to be efficient in estimating the number of flowers, in addition to detecting and segmenting them, qualifying them in terms of color. Therefore, the methodology can be used in the floriculture and landscaping sector to estimate and quantify flowers through images.

**Keywords:** Image analysis. Floriculture. Landscaping. Mask R-CNN. Convolutional Neural Networks.

## 5.1 Introdução

Conhecida popularmente como vinca, a espécie perene *Catharanthus roseus* (L.) G. Don é uma planta ornamental e medicinal. Dentro da floricultura, a vinca é atrativa principalmente pela cor de suas flores, encontradas nas cores brancas e rosadas, o que confere alto valor estético aos jardins e possibilita sua utilização no paisagismo (NEJAT *et al.*, 2015).

Para projetos paisagísticos, há demanda para construção de jardins floridos, funcionais e belos, faz o setor recorrer a tecnologias cada vez mais avançadas. Podemos citar dentre as tecnologias como exemplo, a criação de aplicativos que facilitam o manejo do projetista na identificação de espécies, pelos órgãos da planta, como suas flores (FARIA *et al.*, 2020). A Visão Computacional por meio da análise de imagem e criação de bancos de dados, tem facilitado a realização destas tarefas de forma eficiente e precisa, e tais técnicas podem auxiliar programas de paisagismo como o *Sketchup* e *Photoandscape*.

Tecnologias a partir da Visão Computacional podem ainda ser aplicadas em setores da horticultura, como em manejos de identificação e quantificação de flores para fins alimentícios e medicinais. As flores para fins alimentícios têm ganhado destaque por apresentarem em sua composição princípios bioativos que favorecem dietas mais saudáveis, além de incrementar beleza aos pratos (FERNANDES *et al.*, 2016).

Dentro das técnicas de aprendizado profundo (*deep learning*), as Redes Neurais Convolucionais se apresentam como umas das ferramentas que podem ser manipuladas para auxiliar nos projetos paisagísticos e na manutenção de jardins já implantados, pois tem contribuído para a agricultura de precisão em muitas áreas. As Redes Neurais Convolucionais são utilizadas para realização de tarefas como a análise de imagens digitais, na identificação, detecção e segmentação de diversos objetos (LEE *et al.*, 2016; HE *et al.*, 2017).

Para identificação e quantificação de objetos, as Redes Neurais Convolucionais do tipo Mask R-CNN são as que apresentam arquitetura de rede que realizam tais tarefas, apresentando resultados precisos (LIU *et al.*, 2019). A identificação, detecção e segmentação dos objetos nas imagens são realizados a partir de treinamentos, onde nas imagens são demarcadas com as caixas delimitadoras sobre os objetos de interesse, distinguindo-os quanto a classe determinada (HE *et al.*, 2017).

Desta forma, objetivou-se avaliar o potencial da rede Mask R-CNN nos setores da floricultura e paisagismo para quantificar flores de vinca e as qualificar quanto à cor.

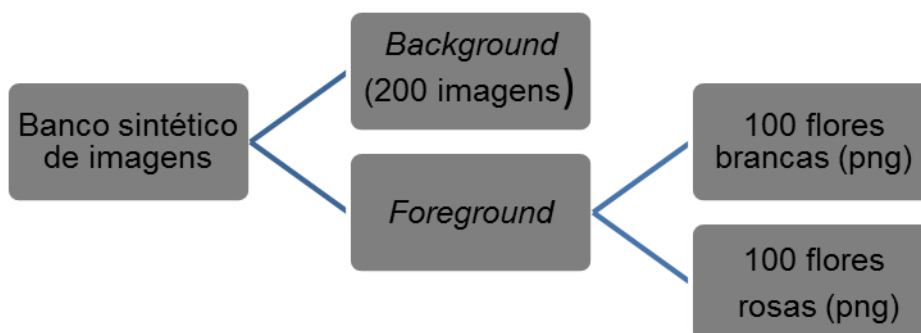
## 5.2 Material e métodos

Foi utilizado um conjunto de imagens da espécie vinca, obtidas por meio de câmeras de dois *smartphones*: (Sony Xperia XA1 Plus, modelo G3426; Abertura:  $f/2$ ; Tempo de exposição: 1/30s; Flash: desligado, Distância focal: 4.22mm; Valor ISO: 50, resolução: 5520x4140 *pixels* e do Redmi Note 9, Xiaomi: Abertura:  $f/1.79$ ; Tempo de exposição: 1/60s; Flash: desligado; Distância focal: 4.74mm; Valor ISO: 228; resolução 8000x6000 *pixels*).

Foram coletadas 700 imagens em jardins no Norte de Minas Gerais na cidade de Montes Claros e Coração de Jesus, as imagens foram obtidas em diferentes dias, entre os meses de março a outubro de 2021, dentro do horário de 7h da manhã até as 16h da tarde, as plantas em que foram tiradas as fotos, eram plantas com mais de 4 meses de idade, o tamanho das plantas variou de 35 a 100 centímetros de altura. Dessas imagens, 500 possuem flores, sendo 384 com flores na cor rosa, variando de tons médios a escuros, 100 imagens com flores na cor branca e 16 contendo flores brancas e rosas. E 200 imagens não possuem flores, contendo apenas folhas da espécie, sendo utilizadas como *background*.

Foi feita à criação de um banco sintético de imagens. Para isso foram criadas imagens em formato *png* (com fundo transparente) contendo apenas a flor, totalizando-se 100 flores brancas de vinca e 100 de flores rosa (FIGURA 1). Na criação do banco sintético, estas imagens em formato *png* compuseram o *foreground* com duas subclasses (vinca branca e vinca rosa). A edição para a obtenção destas imagens *png* foi feita com o auxílio do *software* GIMP versão 2.10.22. Quanto ao *background* considerou-se 200 imagens sem a presença de flores e com um fundo composto apenas por folhas da espécie.


Figura 1 – Banco sintético de imagens para o treinamento



Fonte: Da autora, 2022.

O banco sintético de imagens foi criado no formato COCO com auxílio da biblioteca *cocosynth* (<https://github.com/akTwelve/cocosynth>) no ambiente do *Google colab* utilizando a linguagem de programação *python*. Para isso foi estabelecido o número de 3000 imagens para treinamento e 1000 imagens para validação. Dentro do algoritmo utilizado, estabeleceu-se aleatoriamente o número máximo de cinco objetos *png* por imagem. O posicionamento destas imagens *png* sobre o *background* se deu de forma aleatória. Além disso, para a criação do banco sintético de imagens foram permitidas alterações aleatórias na rotação, escala e brilho para a sobreposição das imagens *png* sobre o *background* (FIGURA 2a). Por meio desta metodologia, a máscara da imagem (FIGURA 2b) e arquivo com as definições das instâncias no formato json foram obtidas automaticamente. O tamanho das imagens de saída foi definido em 320x320 *pixels*.

Figura 2 – Exemplo de imagens do banco sintético com imagens de *png* sobre o *background* (a) e sua respectiva máscara (b) obtida pela biblioteca *cocosynth*



Fonte: Da autora, 2022.

Para o treinamento das redes neurais convolucionais, utilizou-se o algoritmo Mask R-CNN ([https://github.com/matterport/Mask\\_RCNN](https://github.com/matterport/Mask_RCNN)), esta etapa também foi realizada no *Google colab*, o ambiente de execução definido foi o GPU tornando o treinamento mais rápido. A rede utilizada como extratora das características foi a ResNet101 e o modelo pré-treinado MS COCO. No uso do algoritmo Mask R-CNN considerou-se o uso de 5 imagens por GPU, 3 classes (*background*, flores rosas e flores brancas). Na Tabela 1 são resumidas as informações dos demais parâmetros configurados.

Tabela 1 – Parâmetros arbitrados para o ajuste de redes do tipo Mask-RCNN

(Continua)

<b>Parâmetros</b>	<b>Valores</b>
BACKBONE	resnet101
BACKBONE_STRIDES	[4, 8, 16, 32, 64]
BATCH_SIZE	10
BBOX_STD_DEV	[0.1 0.1 0.2 0.2]
COMPUTE_BACKBONE_SHAPE	None
DETECTION_MAX_INSTANCES	100
DETECTION_MIN_CONFIDENCE	0.7
DETECTION_NMS_THRESHOLD	0.3
FPN_CLASSIF_FC_LAYERS_SIZE	1024
GPU_COUNT	2
GRADIENT_CLIP_NORM	5
IMAGES_PER_GPU	5
IMAGE_CHANNEL_COUNT	3
IMAGE_MAX_DIM	320
IMAGE_META_SIZE	15
IMAGE_MIN_DIM	320
IMAGE_MIN_SCALE	0



Tabela 1 – Parâmetros arbitrados para o ajuste de redes do tipo Mask-RCNN

(Conclusão)

<b>Parâmetros</b>	<b>Valores</b>
IMAGE_SHAPE	[320 320 3]
LEARNING_MOMENTUM	0.9
LEARNING_RATE	0.001
MASK_POOL_SIZE	14
MASK_SHAPE	[28, 28]
MAX_GT_INSTANCES	50
MEAN_PIXEL	[123.7 116.8 103.9]
MINI_MASK_SHAPE	(56, 56)
NAME	Vinca
NUM_CLASSES	3
POOL_SIZE	7
POST_NMS_ROIS_INFERENCE	500
POST_NMS_ROIS_TRAINING	1000
PRE_NMS_LIMIT	6000
ROI_POSITIVE_RATIO	0.33
RPN_ANCHOR_RATIOS	[0.5, 1, 2]
RPN_ANCHOR_SCALES	(8, 16, 32, 64, 128)
RPN_ANCHOR_STRIDE	1
RPN_BBOX_STD_DEV	[0.1 0.1 0.2 0.2]
RPN_NMS_THRESHOLD	0.7
RPN_TRAIN_ANCHORS_PER_IMAGE	256
STEPS_PER_EPOCH	50
TOP_DOWN_PYRAMID_SIZE	256
TRAIN_BN	False
TRAIN_ROIS_PER_IMAGE	32
USE_MINI_MASK	True
USE_RPN_ROIS	True
VALIDATION_STEPS	5
WEIGHT_DECAY	0.0001

Fonte: Da autora, 2022.

Foi utilizada a técnica do *Transfer learning*, a qual inicia o treinamento a partir de pesos sinápticos já treinados no formato cocodata. Foram consideradas 100 épocas de treinamento para o ajuste dos pesos sinápticos das últimas camadas da rede e mais 100 épocas para o ajuste dos pesos sinápticos de todas as camadas da rede.

Ao final do treinamento da rede, foi realizado o teste com as imagens. Neste momento, estabeleceu-se a confiança mínima de 90% para a identificação e classificação das flores. Para avaliar a precisão na detecção dos objetos pela Mask R-CNN, construiu-se uma tabela de contingência, resultante da predição da classificação comparada com as classes reais. Utilizaram-se os seguintes avaliadores para verificar a eficiência da rede na detecção dos objetos:

$$\text{Precisão} = \frac{TP}{TP + FP} \quad (\text{eq1})$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (\text{eq2})$$

$$F - 1 = \frac{2 * \text{Precisão} * \text{Recall}}{\text{Precisão} + \text{Recall}} \quad (\text{eq3})$$

$$\text{Acurácia} = \frac{TP + TN}{TP + TN + FP + FN} \quad (\text{eq4})$$

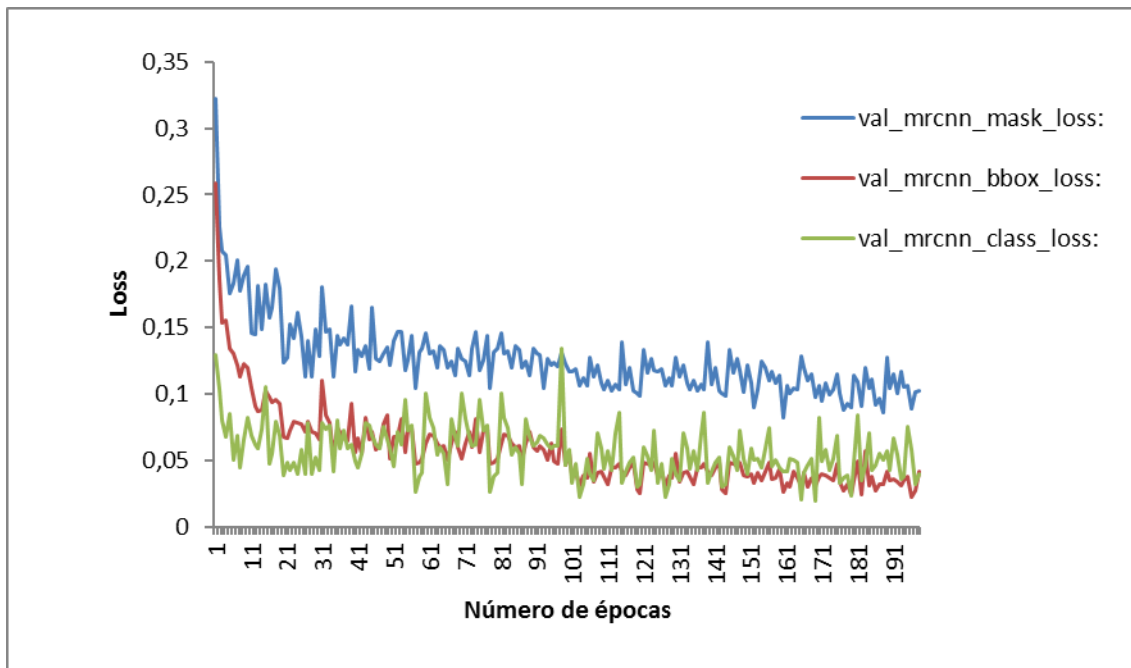
$$\text{Especificidade} = \frac{TN}{TN + FP} \quad (\text{eq5})$$

Onde: TP que se refere aos verdadeiros positivos, FN aos falsos negativos, FP aos falsos positivos e TN aos verdadeiros negativos.

### 5.3 Resultados

As funções de perda para o *mrcnn\_mask\_loss*, a *mrcnn\_bbox\_loss* e a *mrcnn\_class\_loss* são apresentadas na figura 3. Ao observar a função de perda ao longo das épocas de iteração, a partir da época 22 obteve-se estabilização na qualidade do ajuste. Porém, após a centésima época quando deixou-se de treinar apenas a última camada da rede e iniciou-se o treinamento de todas as camadas houve uma pequena melhoria no ajuste, com posterior estabilização.

Figura 3 – Curvas da função de perda por iteração na classificação de flores de *Catharanthus roseus* (L.) G. Don.



Fonte: Da autora, 2022.

Com o treinamento das épocas com o algoritmo Mask R-CNN, obtém-se as imagens segmentadas do conjunto de dados utilizado para o teste, estabelecidas com o valor de confiança de 90%. Na figura 4 pode ser observada como exemplo uma imagem antes da inferência e após com a caixa delimitadora e a máscara de segmentação sobre o objeto detectado e identificado.

Figura 4 – Detecção e identificação da flor de vinca pela caixa delimitadora e máscara de segmentação



Fonte: Da autora, 2022.

A tabela de contingência ou matriz de confusão para as duas subclasses analisadas apresentaram 1719 flores rosas e 443 brancas, tidas como verdadeiros positivos. Para os falsos positivos dentro das imagens, 51 objetos foram classificados como flores rosas e 47 como flores brancas, estes falsos positivos são quando a rede classifica o objeto de forma incorreta. Os falsos negativos ocorreram quando havia flores tanto rosas quanto brancas nas imagens e a rede não conseguiu classificá-las.

Tabela 2 – Tabela de contingência

Classe	Realidade	Classificação pela rede	
		Sim	Não
Vinca branca	Sim	TP = 443	FN = 90
	Não	FP = 47	TN = 157
Vinca Rosa	Sim	TP = 1719	FN = 46
	Não	FP = 51	TN = 157
Vinca (Branca + Rosa)	Sim	TP = 2162	FN = 136
	Não	FP = 98	TN = 314

Fonte: Da autora, 2022.

Para verificar a eficiência da rede estudada foram estimadas a precisão, *recall*, F-1, acurácia e especificidade (TABELA 3). Para as duas subclasses analisadas obtiveram-se maior precisão para a vinca rosa, sendo o valor da precisão de 97% e para a vinca branca o valor foi de 83%, a precisão (*precision*) se refere à quantidade de acertos da classe positiva, indicando o quanto o resultado pode ser verdadeiramente correto.

Para a avaliação de *recall* e F-1, os valores para a vinca rosa foram de 97% em ambas, estas mesmas avaliações para a vinca branca apresentaram o valor de 90% para *recall* e 86% para o F-1. O *recall* se refere às chances da rede detectar de forma correta o objeto de interesse e o F-1 é a média harmônica das métricas precisão e *recall*. Neste estudo tanto a precisão quanto o *recall* apresentaram valores elevados e esta média harmônica permaneceu com os valores de 97% e 86%.

Já para os resultados referentes à acurácia foi possível constatar que, para a vinca rosa o resultado foi superior ao da vinca branca, obtendo-se uma maior qualidade na classificação, tendo uma acurácia de 95% e 81%. Este menor valor obtido para a acurácia da subclasse vinca branca, pode ter ocorrido devido às imagens apresentaram maior quantidade de flores na cor rosa, o que acabou influenciando nos valores utilizados para a equação.

A métrica de avaliação especificidade, refere-se a capacidade que a rede possui em não classificar outros objetos dentro da imagem que não sejam as flores rosas e nem as flores brancas. A porcentagem obtida para esta métrica foi de 77% para a vinca rosa e 64% para a vinca branca.

Os valores obtidos para as métricas em relação às duas subclasses vinca branca mais vinca rosa, pode-se observar que para a precisão, *recall*, F-1 e acurácia na classificação desse

conjunto de dados total, os valores foram acima de 90%. O que demonstra que a rede conseguiu de forma eficiente identificar nas imagens as flores de vinca nas duas cores.

Tabela 3 – Valores referentes à precisão, recall, F-1, acurácia e especificidade avaliadas na classificação das flores de vinca nas cores rosa e branca

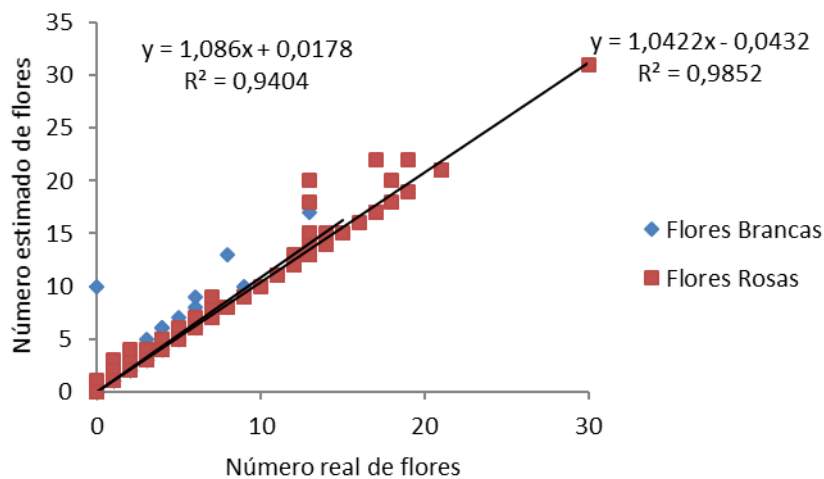
Classes	Precisão	Recall	F-1	Acurácia	Especificidade
Vinca Rosa	97%	97%	97%	95%	77%
Vinca Branca	83%	90%	86%	81%	64%
Vinca (Branca + Rosa)	96%	94%	95%	91%	76%

Fonte: Da autora, 2022.

Nas figuras abaixo é possível observar como a rede foi eficiente em estimar o número de flores do conjunto de imagens. Na Figura 5a é apresentado o número estimado das flores de vinca nas duas cores. Já na Figura 5b pode-se observar a precisão da rede em estimar as flores, independente da cor.

Figura 5 – Estimativa do número de flores rosas e brancas (a) e do número de flores totais (b) em cada foto

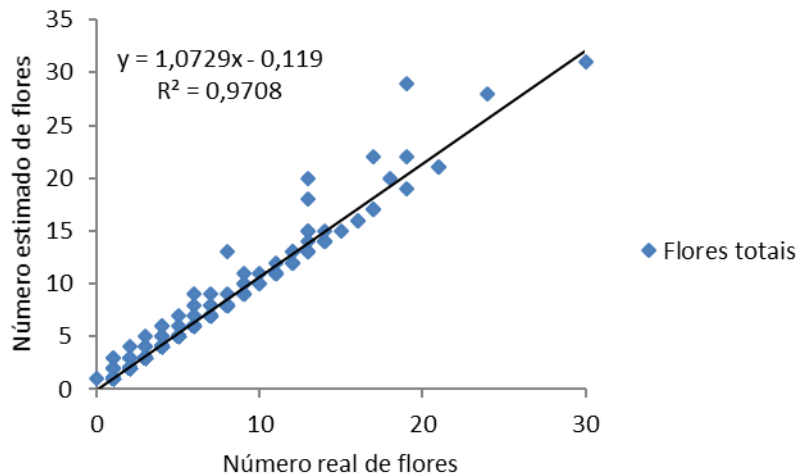
(Continua)



(a)

Figura 5 – Estimativa do número de flores rosas e brancas (a) e do número de flores totais (b) em cada foto

(Conclusão)



(b)

Fonte: Da autora, 2022.

A Rede Neural Convolutiva utilizada, mostrou-se eficiente em estimar o número de flores separadas por subclasses, sendo elas flores na cor branca e na cor rosa, como também, apresentou-se eficiente em estimar o número total de flores independente da cor. Isso mostra que a aplicação da rede para projetos paisagísticos pode funcionar como uma ferramenta eficiente e precisa para determinação de número de flores, seja por cor, ou apenas estimar o número total.

#### 5.4 Discussão

O algoritmo Mask R-CNN é uma metodologia que apresenta alta precisão na detecção e segmentação de imagens (HE *et al.*, 2017). As redes neurais convolucionais, quando utilizadas em análise de imagem, conseguem fazer a partir de um treinamento da rede, a extração de características de um respectivo objeto dentro da imagem estudada (KHAN, 2020).

As taxas de perdas no decorrer das iterações, demonstra a eficiência das redes em se ajustar para possibilitar a detecção das flores (FIGURA 3), pois houve a redução para as suas estimativas, para: A "mrcnn\_mask\_loss", que equivale às máscaras criadas na identificação dos objetos; a "mrcnn\_bbox\_loss" referente à perda atribuída na localização de uma caixa delimitadora (bounding box) na identificação da classe; e a "mrcnn\_class\_loss" que está associada a perda atribuída para a classificação inadequada de objetos que estão na região proposta (region proposal) (BOBBA, 2019).

Quanto menor são os valores apresentados pelas funções de perda na iteração, maiores são as chances das predições saírem corretamente como nas imagens reais (TIAN *et al.*,

2020). Além disso, houve a estabilização das curvas destas funções de perda, indicando que o aumento do número de iterações não traria melhoria na qualidade do ajuste.

Para os avaliadores de qualidade na classificação pela Rede Neural Convolutacional, neste trabalho realizado para detecção de flores com a utilização das Redes Neurais Convolucionais, a precisão apresentou bons resultados, com uma estimativa de até 97% o que comprova a eficiência da rede para detecção de flores, mesmo quando são mais de duas classes, e as flores apresentam formato e colorações distintas (TABELA 3).

Em um conjunto de dados composto por flores de macieiras treinado com as Redes Neurais Convolucionais, utilizando apenas 100 imagens de teste e a mesma rede extratora ResNet101 utilizada em nosso trabalho, Tian *et al.* (2020), conseguiram obter além de uma precisão média de 95,90%, obtiveram a taxa de recall em torno de 95,37% e F-1 de 95,90%. Segundo os autores, estas taxas superam outros trabalhos realizados anteriormente com a finalidade de segmentar flores em imagens.

De acordo com Tan, Zhao e Wu (2016) e Hiary *et al.* (2018), quanto maior o conjunto de dados, ou seja, quanto maior o número de imagens dentro do conjunto, melhor será a classificação, robustez e precisão da metodologia utilizada. Hiary *et al.* (2018), ao utilizarem as Redes Neurais Convolucionais para classificação de uma gama de flores, de tipos e formatos diferentes em três conjuntos de dados, seus resultados de segmentação e detecção das flores apresentaram uma porcentagem de 80% para a classificação correta das imagens sobre todas as imagens dos conjuntos. Segundo os autores, foi possível obter 97% para classificação desses mesmos conjuntos, onde apenas 168 imagens dentro de um total de 10.000 foram classificadas de forma incorreta.

Na detecção e classificação de flores abertas e fechadas de uva Pahalawatta *et al.* (2020), ao utilizar a arquitetura Mask R-CNN, o treinamento da rede foi capaz de diferenciar as duas classes propostas sendo elas flores abertas e fechadas. É possível observar que a precisão da utilização da Rede Neural Convolutacional para determinadas tarefas como esta, apresentam resultados superiores quando comparados a atividades que seriam realizadas de forma manual. Como por exemplo o manejo de definir quais são flores abertas e quais são flores fechadas na inflorescência de videiras.

Foi possível observar que para os valores relacionados ao coeficiente de determinação a capacidade da rede em detectar flores de cor rosa e branca e a quantidade total de flores obteve-se valores próximo a 1. Pahalawatta *et al.* (2020) também conseguiram obter altos valores, em relação ao número total real de flores e o número previsto, com  $R^2 = 0,815$  e para a proporção real para flores fechadas quanto para flores totais o valor foi de  $R^2 = 0,74$ , o que afirma a boa capacidade e eficiência da rede ao realizar a detecção dos objetos designados.

A utilização de metodologias de aprendizado profundo também foram utilizadas por Wu *et al.* (2020) para detecção rápida e precisa de flores de macieiras, as redes neurais utilizadas foram capazes de fazer detecções rápidas e precisas, mesmo levando em conta que a flor da macieira apresenta tamanho reduzido e as imagens estavam com diferentes iluminações. O

processo auxilia principalmente na previsão de rendimento do pomar, além disso o valor referente a precisão foi de 97,31%.

Para o processamento de imagens utilizando os métodos de deep learning, quanto maior a quantidade de dados, melhor serão as amostras de treinamento e assim é possível obter o máximo desempenho da rede e modelo que serão utilizados para segmentação, detecção e identificação de objetos em imagens (TAN; ZHAO; WU, 2016).

No entanto, embora a quantidade de imagens utilizadas por Tian *et al.* (2020) e no presente trabalho, teve-se boa eficiência no treinamento das redes. Isto pode ser explicado pelo treinamento recorrendo a criação do banco sintético de imagens. A criação de um banco sintético de imagens permite melhorias no desempenho da rede e nos resultados referentes a segmentação (SOBHANINIA *et al.*, 2019). Quando a quantidade de imagens de um conjunto de dados é relativamente pequena para realizar o treinamento de um modelo, a criação de um banco sintético torna-se uma ferramenta importante, capaz de aumentar o desempenho do modelo a ser treinado, e aumenta as chances de acertos na detecção dos objetos nas imagens (PATRAWALA, 2020).

Diferentes técnicas utilizando a Visão Computacional vêm sendo empregues em atividades para auxiliar em tarefas realizadas pelo setor da floricultura e no paisagístico. Como a utilização da Visão Computacional na contagem de plantas por meio de imagens de satélite (DA SILVA, SANTOS FILHO, DA SILVA, 2019).

A criação de aplicativos que auxiliam principalmente na identificação e reconhecimento de espécies, estes utilizam a Visão Computacional como estratégia para criação de banco variado de imagens de plantas e se tornam ferramentas didáticas que auxiliam no processo de ensino-aprendizagem na construção de projetos paisagístico, substancialmente para paisagistas pouco experientes ou até mesmo para leigos (FARIA *et al.*, 2020).

A Visão Computacional tem contribuído na identificação e classificação de espécies de elevada importância comercial como exemplo, as orquídeas do gênero *Cattleya*, gênero que compõe dezenas de espécies em que muitas flores são bem semelhantes (AZEVEDO, 2016). Processos de identificação de flores se apresentam como tarefas complexas, e a automação destes processos que envolvem identificação podem contribuir e beneficiar diversos profissionais e setores.

Para a identificação das flores de *Catharanthus roseus* (L.) G. Don, o treinamento utilizando a Rede Neural Convolucional Mask R-CNN apresentou boa precisão, o que viabiliza a rede como uma ferramenta aliada para produtores de flores e paisagistas, podendo ser utilizada para detectar flores em diferentes estágios de desenvolvimento, identificar flores quanto a coloração e quantifica-las a partir de imagens.

## 5.5 Conclusão

O modelo Mask R-CNN foi eficiente em estimar o número de flores, detectar e segmentar as flores quanto a coloração. Logo, a metodologia utilizada é uma ferramenta útil para ser



empregada nos setores de floricultura e paisagismo por meio da quantificação e qualificação de flores por meio de imagens.

## 5.6 Referências

AZEVEDO, L. P. de. **Aplicação de redes neurais artificiais no processo de qualificação de orquídeas do gênero *Cattleya***. 2016. 48 f. Monografia (Bacharelado em Sistemas de Informação) – Instituto Federal de Minas Gerais, Sabará, 2016.

BOBBA, R. Taming the Hyper-parameters of Mask RCNN, Analytics Vidhya: Community of Analytics and Data Science Professionals. *In: Analytics Vidhya*. 2019. Disponível em: <https://medium.com/analytics-vidhya/taming-the-hyper-parameters-of-mask-rcnn-3742cb3f0e1b>. Acesso em: 2 mar. 2022.

DA SILVA, P. D.; SANTOS FILHO, T. A.; DA SILVA, S. F. Metodologias de visão computacional para contagem de plantas por meio de imagens de satélites. *In: Escola regional de informática de Goiás*, 8., 2019, Goiânia. [Anais...]. Goiânia, 22 e 23 nov. 2019. Disponível em: <https://sol.sbc.org.br/index.php/erigo/article/view/9092/8994>. Acesso em: 31 jan. 2022.

FARIA, G. H. C.; CORREA, S. D.; VAZ, C. E. V.; NASCIMENTO, E. C. O uso de mídias móveis aplicado ao ensino aprendizagem de paisagismo. **Arquitetura Revista**, v. 16, n. 2, jul./dez. 2020.

FERNANDES, L.; CASAL, S.; PEREIRA, J.A.; SARAIVA, J. A.; RAMALHOSA, E. Uma perspectiva nutricional sobre flores comestíveis. **Acta Portuguesa da Nutrição**, v. 6, p.32-37, 2016. Disponível em: <https://bibliotecadigital.ipb.pt/handle/10198/14274>. Acesso em: 2 mar. 2022.

HIARY, H.; SAADEH, H.; SAADEH, M.; YAQUB, M. Flower classification using deep convolutional neural networks. **ET Comput. Vis.**, v. 12, n. 6, p. 855-862, 2018.

HE, K.; GKIOXARI, G.; DOLLAR, P.; GIRSHICK, R. Mask R-CNN. *In: IEEE INTERNATIONAL CONFERENCE ON COMPUTER VISION (ICCV)*, 2017, Venice, Italy. **Proceedings** [...]. Venice, Italy, 2017. DOI: 10.1109/iccv.2017.322.

KHAN, A.; SOHAIL, A.; ZAHOORA, U.; QURESHI, A. S. A survey of the recent architectures of deep convolutional neural networks. **Artificial Intelligence Review**, v. 53, n. 8, p. 5455–5516, 2020. DOI: 10.1007/s10462-020-09825-6.

LEE, S. H.; CHANG, Y. L.; CHAN, C.S.; REMAGNINO, P. Plant identification system based on a convolutional neural network for the lifeclef. **Plant Classification Task**, 2016. Disponível em: <http://ceur-ws.org/Vol-1609/16090502.pdf>. Acesso em: 28 out. 2021.

LIU, X.; DENG, Z.; YANG, Y. Recent progress in semantic image segmentation. **Artif Intell Rev.**, v. 52, p. 1089–1106, 2019. Disponível em: <https://doi.org/10.1007/s10462-018-9641-3>. Acesso em: 19 dez. 2021.

NEJAT, N.; VALDIANI, A.; CAHILL, D.; TAN, Y-H.; MAZIAH, M.; ABIRI, R. "Ornamental Exterior versus Therapeutic Interior of Madagascar Periwinkle (*Catharanthus roseus*): the two faces of a versatile herb". **The Scientific World Journal**, 2015. 19 p. DOI: <https://doi.org/10.1155/2015/982412>. Acesso em: 2 abr. 2022.

PAHALAWATTA, K.; FOURIE, J.; PARKER, A.; CAREY, P.; WERNER, A. Detection and classification of opened and closed flowers in grape inflorescences using Mask R-CNN. University of Canberra. *In: INTERNATIONAL CONFERENCE ON IMAGE AND VISION COMPUTING NEW ZEALAND (IVCNZ)*, 35., 2020, [s.l.]. **Proceedings** [...]. [S.l.], 2021. p. 1-6. DOI: 10.1109/IVCNZ51579.2020.9290720.

SOBHANINIA, Z.; RAFIEI, S.; EMAMI, A.; KARIMI, N.; NAJARIAN, K.; SMAVI, SHADROKH.  
SOROUSHMEHR, S. M. R. **Fetal Ultrasound Image Segmentation for Measuring Biometric Parameters Using Multi-Task Deep Learning**. 2019. Disponível em:  
<https://arxiv.org/ftp/arxiv/papers/1909/1909.00273.pdf>. Acesso em: 6 jan. 2022.

TAN, W.; ZHAO, C.; WU, H. Intelligent alerting for fruit-melon lesion image based on momentum deep learning. **Multimedia Tools and Applications**, v. 75, p. 16741-16761, 2016.

TIAN, Y.; YANG, G.; WANG, Z.; LI, E.; LIANG, Z. Instance segmentation of apple flowers using the improvised mask R-CNN model. **Biosystems engineering**, v.193, p. 264-278, 2020.

WU, D.; LV, S.; JIANG, M.; SONG, H. Using channel pruning-based YOLO v4 deep learning algorithm for the real-time and accurate detection of apple flowers in natural environments. **Computers and electronics in agriculture**, v. 178, Nov. 2020.

## 6 CONSIDERAÇÕES FINAIS

O modelo Mask R-CNN é uma ferramenta dentro da Visão Computacional útil para produtores de flores, para aplicação em campo, como para avaliar produção de flores de corte, estimar quantidade de flores a serem colhidas por hectares e até mesmo programar colheitas, assim como detectar abertura floral. No paisagismo, o modelo pode facilitar a implantação e manutenção de jardins, e a ferramenta pode ser auxiliar em *softwares* de desenho assistido utilizados para criação de projetos paisagísticos.