

APLICAÇÃO DE REDES NEURAI PROFUNDAS PARA DETECÇÃO E CLASSIFICAÇÃO DE PLANTAS DANINHAS E SEU ESTADO DA ARTE.

Luiz Carlos Marques Junior ¹
José Alfredo Ulson Covolan ²

RESUMO

Ervas daninhas competem por recursos naturais tanto em áreas florestais, prejudicando o desenvolvimento da vegetação nativa, quanto em áreas agrícolas, afetando a qualidade das culturas cultivadas. Assim, surge a necessidade de realizar a classificação destas espécies, para que se possa corretamente aplicar métodos mecânicos ou químicos para a contenção das pragas. Esta pesquisa, apresenta aplicação e comparação de técnicas de aprendizado de máquina (Machine Learning), com o intuito de automatizar a classificação de imagens para desafios agrícolas, como a detecção de sementes defeituosas, plantas daninhas e classificação entre estas e a vegetação nativa, ao final é apresentada a arquitetura de uma Rede Neural Convolutacional. Como diferencial destaca-se a capacidade de autoaprendizagem da rede, uma vez que, na maioria dos casos as imagens são coletadas sob condições não ideais ,a diferentes alturas e níveis de iluminação. Espera-se por meio desta pesquisa contribuir com informações significantes em relação a técnicas de inteligência artificial, que podem ser utilizadas na classificação de imagens de plantas daninhas, fator que contribuirá para ramo florestal e agrícola.

PALAVRAS-CHAVE: Ervas daninhas, aprendizado de máquina, rede neural convolutacional

ABSTRACT

Weeds compete for natural resources both in forest areas, harming the development of native vegetation, and in agricultural areas, affecting the quality of cultivated crops. Thus arises the need for the classification of these species so that they can properly apply mechanical or chemical methods to contain the pests. This research presents the comparison and application of machine learning techniques in order to automate the classification of images related to weeds and native vegetation and at the end it is presented the architecture of a Convolutional Neural Network. As a differential, the self-learning ability of the network stands out, an important factor since, in most cases, the images are collected under non-ideal conditions at different height and lighting levels. It is hoped through research to contribute significant information regarding the artificial intelligence techniques that can be used in weed image classification, which will contribute significantly in the forestry and agricultural industry.

KEY WORDS: Weeds, Machine Learning, Convolutional Neural Networks.

¹ Mestrando em Engenharia Elétrica UNESP BAURU.

² Prof. Dr de Engenharia Elétrica UNESP BAURU.

INTRODUÇÃO

De acordo com informações do ministério da Agricultura, Pecuária e Abastecimento, a agricultura participa com cerca de 24% do Produto Interno Bruto (PIB) do Brasil. Um estudo realizado pelo departamento de Agricultura dos Estados Unidos reforça, apontando que de 2006 a 2010 o rendimento da agropecuária cresceu 4,28% ao ano no Brasil. O principal motivo para o aumento de produtividade deve-se aos investimentos em ciência e tecnologia, na área agrícola e florestal, como aprimoramento genético de sementes para o plantio e cultivo dos alimentos.

Entretanto, um desafio que existe tanto na área agrícola como também na florestal, é encontrar métodos que permitam quantificar e qualificar de maneira automática espécies exóticas com potencial de invasão, conhecidas também como plantas daninhas. Dentre os prejuízos que as ervas daninhas geram destacam-se a redução na produtividade das culturas, em um cenário mais extremo os prejuízos podem chegar a perda total da lavoura. (FONTES et al, 2003^a). Outro desafio está relacionado a alta rusticidade dessas plantas, já que se beneficiam no processo de competição, assim, reduzindo a eficiência agrícola, aumentando os custos e diminuindo a qualidade do produto e seu valor comercial (Vasconcelos et al, 2012).

Com essas ferramentas em mãos, tem-se o desafio de classificar as imagens e a obter dados relevantes a partir das mesmas. O domínio de tais técnicas é essencial, pois é um diferencial econômico e uma importante ferramenta de informação para o gerenciamento sustentável e eficaz, para a área agrícola e florestal do mundo. Do ponto de vista científico a obtenção desses dados significa ter um elevado nível de controle sobre área de interesse, já do ponto de vista econômico, a utilização de tais técnicas representam uma economia significativa em mão de obra, e uso adequado de agentes para controle de pragas.

Neste trabalho o estado da arte da classificação de imagens agrícolas, fazendo uso de técnicas de *Machine Learnig* será apresentado, tem-se como objetivo, que por meio deste artigo o leitor consiga adquirir maior bagagem de informações, desta maneira selecionar qual método melhor adequa-se para sua aplicação.

1. METODOLOGIA

1.1 Processamento de imagens.

(Vadivambal, R, 2016) Define imageamento biológico como uma tecnologia de visão computacional, que usa visão artificial ao invés da humana para observar, capturar, processar e apresentar o objeto de interesse. Os autores dividem o processamento das imagens biológicas nos seguintes passos:

“Aquisição de imagens, processamento de imagens, aprimoramento, segmentação, representação e descrição e reconhecimento”.
(Vadivambal, R, 2016).

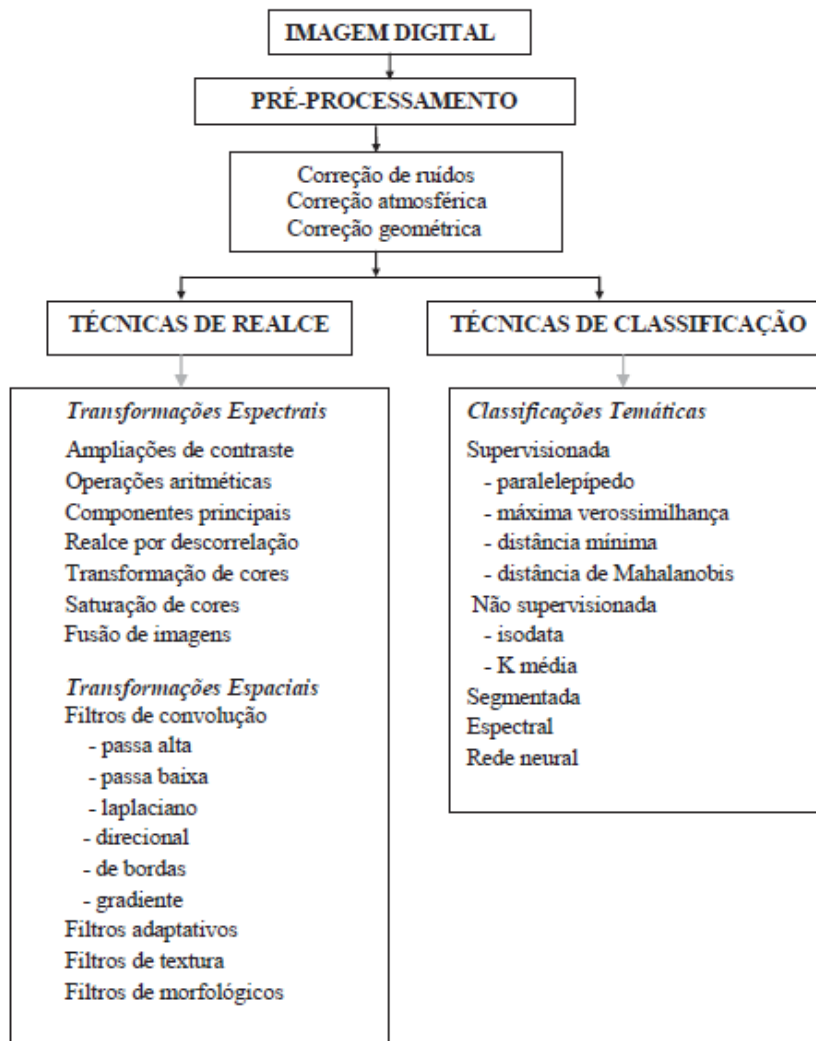
A classificação de imagens pode ser amplamente dividida entre aprendizado não supervisionado e aprendizado supervisionado, sendo que no processamento de imagens a classificação é o último estágio que envolve identificação de um objeto, e o distingue em uma classe, comparando as características do objeto de interesse com um objeto conhecido ou um conjunto de critérios conhecidos. (Vadivambal, R, 2016).

(Meneses et.al 2012a), aprofunda-se nessa definição relatando que:

“Os diversos métodos de classificação em uso podem ser divididos segundo diferentes critérios: Classificação paramétrica e não-paramétrica, classificação espectral e espacial, e classificação supervisionada ou não-supervisionada. Há ainda a possibilidade de dividir os classificadores em classificação por pixel ou por regiões. A maioria dos classificadores executa a classificação por pixel, que se utiliza somente da informação espectral de cada pixel para encontrar regiões homogêneas, a partir de medidas de distâncias ou de probabilidades de um pixel pertencer a uma classe específica. Na classificação por regiões o processo de decisão leva em consideração um agrupamento de pixels que é usado como unidade de classificação”.

A figura 1 descreve os principais métodos de processamento e classificação de imagem.

Figura 1 – Apresentação das principais técnicas de processamento de imagens segundo um modelo geral de divisão dos tipos de processamento



Fonte: Meneses et.al (2012)

Ainda sobre os principais métodos para a classificação das imagens, resumidamente podemos dividi-los em estatísticos, com destaque para o *Support Vector Machine* (SVM), *Randon Forest* e Redes Neurais Artificiais (RNN), que é o método de enfoque deste trabalho.


Nos capítulos a seguir o estado da arte dos métodos mencionados acima são apresentados, juntamente com os resultados obtidos pelos autores

1.2 Máquina de Vetores de Suporte (*Support Vector Machine*)

A primeira definição de máquina de vetores de suporte (*Support Vector Machines- SVM*) foi definida por Vladimir Vapnik, aonde a forma linear constitui um

hiperplano para que haja uma margem, separando um conjunto de exemplos positivos e negativos em um espaço com um alto número de dimensões, uma vez que pode haver infinitas escolhas para a margem que faça a separação desses exemplos, sendo que o objetivo é maximizar a distância dessa margem aos exemplos negativo e positivo mais próximos.(SANTOS, 2017).

Figura 2 – Representação do método de Máquina de Vetores de Suporte



Fonte: Quora (2018)

Pode-se compreender a máquina de vetores de suporte como um classificador de margem máxima, por exemplo, para um determinado número de amostras em duas classes o SVM deriva a função de classificação que é o hiperplano na máxima distância dos pontos mais próximos pertencentes a ambas as classes.

(Karimi et al, 2006) em seu trabalho fez uso da máquina de vetores de suporte para a detecção de ervas daninhas e a deficiência de nitrogênio em plantações de milho. Este estudo demonstrou a capacidade do método para analisar dados hiperspectrais para identificar estresses de plantas daninhas e nitrogênio no milharal em fase inicial de crescimento. Forneceu uma precisão de classificação razoável para taxa combinada de plantas daninhas e aplicação de nitrogênio (69%). Resultados de classificação mais precisos foram obtidos quando plantas daninhas e tratamentos com nitrogênio foram investigados separadamente (86 e 81%, respectivamente). Usando uma validação cruzada

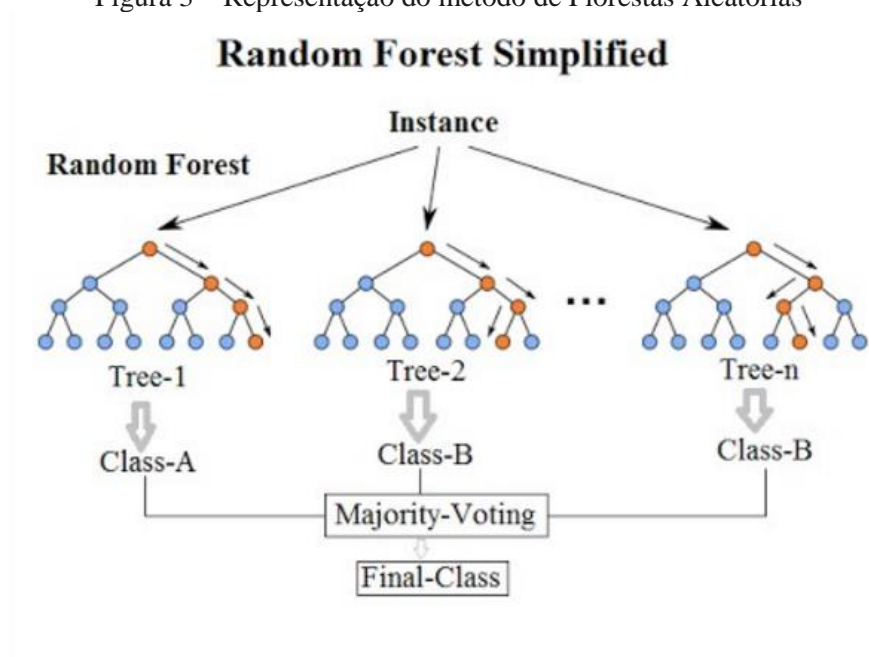
de 10 vezes (teste conjunto de dados) com este método, foi obtido uma precisão de classificação variando de 66 a 76%, para a aplicação combinada de ervas daninhas e nitrogênio. No estudo os autores conseguiram utilizar o SVM para detectar problemas com nitrogênio e ervas daninhas, permitindo assim que intervenções corretivas oportunas ocorram na mesma estação de crescimento.

1.3 Florestas Aleatórias (*Random Forests*)

Florestas Aleatórias ou (*Random Forest, RF*) são uma coleção de árvores de decisão, consiste em um nó interno que denota naturalmente problemas de reconhecimento de padrões com mais de duas classes. Para classificação existem três elementos chave para a árvore de decisão que são partição de dados, lista de recursos e funções divididas.

Em florestas aleatórias, a construção de cada árvore depende dos valores de um vetor aleatório selecionado a partir da amostra original, é ensacado em conjunto. A seleção de atributos pode ser usada na construção de florestas aleatórias, para gerar a instância da amostra. Este procedimento é feito via seleção randômica, para testar o método usam a estratégia de votação. (Long,2014)

Figura 3 – Representação do método de Florestas Aleatórias



Fonte: Medium (2018)

(Yilin Long 2014) fez uso de máquina de vetores de suporte e florestas aleatórias para o reconhecimento de sementes defeituosas. Os resultados obtidos no experimento são apresentados na tabela 1.

Tabela 1- Resultados obtidos da comparação dos métodos de Máquina de Vetores de Suporte e Florestas Aleatórias

TABLE I
SUPPORT VECTOR MACHINE CLASSIFIER AND RANDOM FOREST CLASSIFIER
ACCURACY AS PERCENTAGE OF CORRECT SEED IDENTIFICATIONS

Features	Linear SVM Accuracy (%)	RBF SVM Accuracy (%)	RF Accuracy (%)
Gist	91.208	91.593	91.98
GistHog	94.161	94.16	92.50
GistHogMidLevel	91.792	91.801	89.49
GistHogMidLevelRgb	93.974	93.993	91.42
GistHogRgb	95.265	95.21	94.10
GistMidLevel	87.319	87.376	87.31
GistRgb	93.711	93.975	92.60
GistRgbMidLevel	91.818	91.707	89.98
Hog	92.934	92.887	90.16
HogMidLevel	89.223	89.185	85.75
HogMidLevelRgb	92.897	92.895	89.41
HogRgb	94.723	94.667	93.53
MidLevel	73.592	74.077	67.48
MidLevelRgb	88.097	88.08819	83.90
Rgb	90.236	90.76	88.85

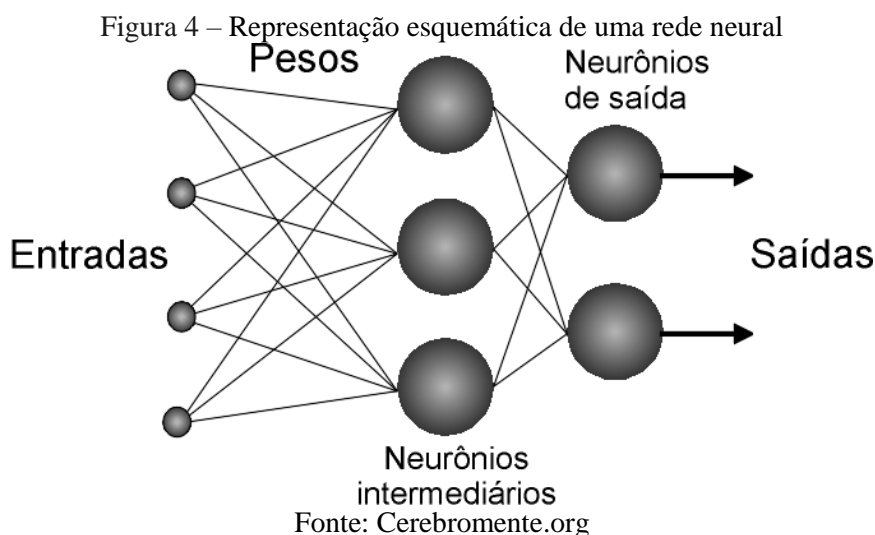
Fonte: Long et al

Ambos os métodos tiveram desempenho similar, sendo que a melhor taxa de reconhecimento é de 95,265% usando a máquina de vetores de suporte com os recursos de combinação de Gist, Hog e RGB.

Vale ressaltar que, tanto o método de máquina de vetores como o de florestas aleatórias são estatísticos, que foram aplicados amplamente antes do surgimento das redes neurais convolucionais. Com o aumento da capacidade de processamento dos computadores redes convolucionais vem sendo empregadas em diferentes tarefas, envolvendo imagens e tem apresentado resultados expressivos, nos próximos capítulos são abordados os conceitos das redes neurais e das redes neurais convolucionais.

1.4 Redes Neurais Artificiais.

Dr. Robert Hecht-Nielsen define uma Rede Neural Artificial como “Um sistema de computação constituído por uma série de simples elementos de processamento altamente interligados, que processam informações por sua resposta de estado dinâmico a entradas externas”. (Cauldill, 1987). O princípio de uma rede neural é a soma das entradas ponderadas nos neurônios, assim enviando os resultados para uma função de transferência para produzir uma saída. (Vadivambal, R, 2016). A figura 4 representa o princípio básico do neurônio artificial.



(Dyrman, 2017) informa que métodos populares de *Machine Learning* como *Support Vector Machines* (SVM), *Randon Forest* (RF) e *K-nearest neighbours* (KNN) foram usados previamente para classificação de plantas daninhas. (Raschka, 2016)

Complementa informando que esses modelos não são paramétricos, o que significa que a complexidade dos modelos depende do número de amostras para o treinamento.

(Bolo, 2007). Informa que “Uma rede neural tem a habilidade para extrair padrões e detectar tendências em um conjunto de dados complicados ou imprecisos”. As redes neurais artificiais, junto com o aumento da capacidade de processamento dos computadores, tornaram possível atingir um novo patamar no processamento e classificação de imagens. Esse novo patamar é o desenvolvimento das redes neurais profundas (*Deep Neural Networks*, DNN) e as Redes Neurais Convolucionais (RNC).

1.5 Redes Neurais Convolucionais

A primeira Rede Neural Convolucional (RNC) foi proposta por LeCun et al. (1995) como método de obtenção de tradução de classificação invariante para códigos postais em *scans* de envelopes. Nos anos seguintes as redes neurais convolucionais foram usadas com sucesso para diferentes objetivos como reconhecimento facial, de escrita e fala. Recebendo destaque os trabalhos de (Lang et al., 1990; Nowlan e Platt, 1995; Lecun e Bengio, 1995; Lawrence et al., 1997; Espinosa-Romero,2001).

Até o ano de 2012 o enfoque dos trabalhos na área de classificação de imagens, utilizavam principalmente *Support Vector Machines* (SVM), *Randon Forest* (RF) e *Bootsting*. As redes neurais convolucionais ganharam destaque atualmente devido ao trabalho de Krizhevsky et al. (2012) que estabeleceu o novo recorde no *ImageNet Large Scale Reconignition Challenge* (O *ImageNet Challenge* é uma competição de classificação de imagens, aonde existem mais de 1000 diferentes classes de imagens). O trabalho realizado por Krizhevsky et al. (2012) apresentou uma margem de 10,9 por cento acima do segundo colocado, assim tendo uma performance e precisão consideravelmente maior.

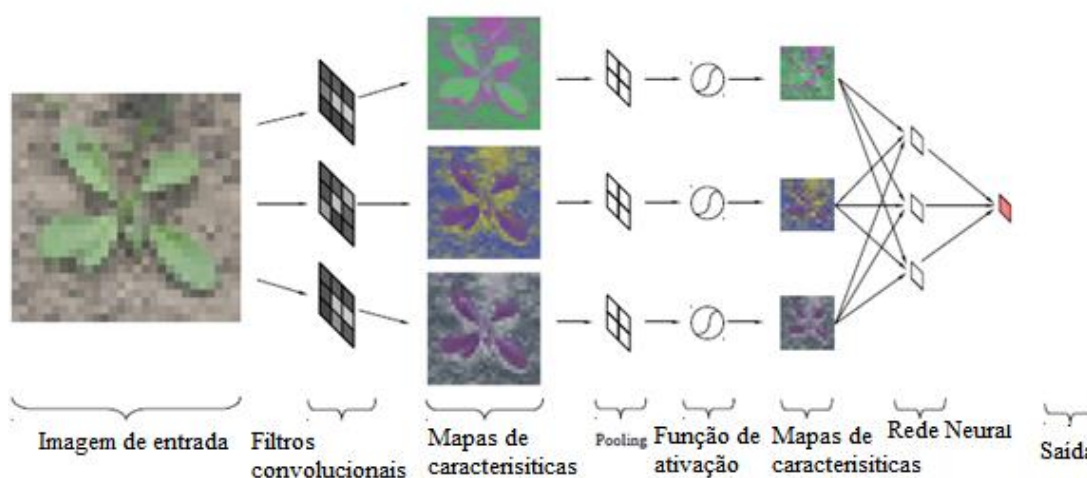
Ao contrário das técnicas estatísticas tradicionais como (SVM/RF/KNN), a complexidade da rede neural convolucional é independente ao número de amostras. Em troca ela requer um conjunto de dados relativamente grande para o treinamento de seus parâmetros. Os modelos da rede neural profunda são flexíveis e têm a capacidade para aprender dados não-lineares complexos (Deng, 2011). A arquitetura de uma rede neural convolucional baseia-se em construir uma hierarquia de características auto aprendíveis, comparado com métodos de classificação anteriores, à torna mais robusta, uma vez que

as informações aprendidas pela rede permitem que a *DNN* tenha a capacidade de distinguir o grau de relevância de cada característica.

(DYRMAN,2017) conceitua uma *Deep Convolutional Network* (Rede Convolutacional Profunda) como “Uma hierarquia de características auto aprendizáveis, as quais são baseadas em recursos menos abstratos das camadas anteriores da rede”.

O aprendizado dos pesos é orientado de acordo com os dados, portanto, grandes quantidades de imagens são necessárias. A figura 5 expressa a estrutura de uma rede neural profunda.

Figura 5 – Representação de uma Rede Neural Convolutacional



Fonte: Dyrman (2017)

(SANTOS, 2017) aprofunda a definição informando que:

“Redes Neurais Convolucionais Profundas foram o primeiro sucesso confiável de treinamento onde múltiplas camadas de uma hierarquia foram treinadas de maneira robusta. Elas constituem uma escolha de topologia ou arquitetura projetada para reduzir o número de parâmetros a serem aprendidos, otimizando o tempo de treinamento através de backpropagation. ConvNets são projetadas para processar dados armazenados na forma de múltiplas matrizes de uma dimensão para sinais e sequências”

(Dyrman 2017) em sua dissertação de doutorado realizou a detecção e classificação de ervas daninhas de maneira automática utilizando Redes Neurais Convolucionais. O autor obteve a precisão de 87% na qual classificou-se 17 espécies distintas de ervas daninhas. Para a coleta destas imagens fez-se uso de trator com uma câmera de alta velocidade acoplada, percorrendo o capó de testes com uma margem de

até 50km/h. Como diferencial o autor realizou a classificação de espécies distintas de ervas daninhas em diferentes condições de clima e iluminação, utilizando para sua base de dados imagens no espectro RGB.

(SANTOS, 2017) em sua dissertação de mestrado fez uso da Rede Neural Convolutacional *CaffeNet* para a classificação de plantas daninhas em uma lavoura de soja no Mato Grosso do Sul. Para a coleta de imagens o autor fez uso de um VANT (Veículo Aéreo não Tripulado) *Phanton 3*, em uma área de 1 hectare com altura média para coleta de imagens de 4 metros, dividiu as plantas daninhas entre plantas de folha larga e de folha estreita. Os resultados foram positivos obtendo-se 98% de precisão para a classificação das espécies.

CONSIDERAÇÕES FINAIS

Técnicas eficientes para a classificação de ervas daninhas são de extrema importância, neste artigo o estado da arte, assim como a metodologia e os resultados obtidos por autores que fizeram uso de modelos estatísticos como as florestas aleatórias ou métodos mais atuais como as redes neurais convolucionais foram apresentados, espera-se que por meio dos dados expostos o leitor tenha maior conhecimento sobre as metodologias que podem ser utilizadas para a agrícola .

Para trabalhos futuros pretende-se utilizar e comparar diferentes arquiteturas de redes neurais convolucionais, para a detecção de ervas daninhas, assim contribuindo com mais informações sobre a utilização das mesmas e suas particularidades.

REFERÊNCIAS BIBLIOGRÁFICAS

Bolo, F. 2007. **A basic introduction to neural network**. Department of Computer Science, University of Wisconsin-Madison. <http://pages.cs.wisc.edu/~bolo/shipyard/neural/local.html> (accessed October 31, 2013).

Caudill, M. 1987. **Neural network primer: Part I**. *AI Expert* 2(12): 46–52.

CEREBROMENTE. **O que são as Redes Neurais Artificiais** <http://www.cerebromente.org.br/n05/tecnologia/rna.htm> (Acessado 20 Agosto, 2016).

Dyrman, M. *Automatic Detection and Classification of Weed Seedlings under Natural Light Conditions*. University of Southern Denmark. 2017.

JUNIOR, Luiz C. M.; COVOLAN, José A. U. **APLICAÇÃO DE REDES NEURAI PROFUNDAS PARA DETECÇÃO E CLASSIFICAÇÃO DE PLANTAS DANINHAS E SEU ESTADO DA ARTE**.

Espinosa-Romero, A. (2001). *Situated Face Detection*. PhD thesis, University of Edinburgh.

FONTES, José. R. A. *Manejo Integrado de Plantas Daninhas*. Documentos 113. Planaltina. Dez. 2003.

J. C. Platt. **Sequential Minimal Optimization: A Fast Algorithm for Training Support Vector Machines**. Microsoft Research, 1998.

Karimi .Y, Prasher. S.O, Patel .R.M, Kimb .S.H: **Application of support vector machine technology for weed and nitrogen stress detection in corn**. Northwest A&F University, 2014.

Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2012). **ImageNet Classification with Deep Convolutional Neural Networks**. *Advances In Neural Information Processing Systems*, pages 1–9.

Lang, K. J., Waibel, A. H., and Hinton, G. E. (1990). **A time-delay neural network architecture for isolated word recognition**. *Neural Networks*, 3(1):23–43.

Lawrence, S., Giles, C. L., Tsoi, A. C., and Back, A. D. (1997). **Face recognition: a convolutional neural-network approach**. *IEEE Transactions on Neural Networks*, 8(1):98–113.

Lecun, Y. and Bengio, Y. (1995). **Convolutional Networks for Images, Speech, and Time-Series**. In Arbib, M., editor, *InM. A. Arbib, editor, The Handbook of Brain Theory and Neural Networks*, pages 1–14. MIT Press.

Long, Y. Cai, Cheng (2014). **Weed Seeds Recognition via Support Vector Machine and Random Forest**

MENESES, R. P.; ALMEIDA, T. *Introdução ao Processamento de Imagens de Sensoriamento Remoto*, UNB. 2012.

MEDIUM. Random Forest Simple **Explanation**. <https://medium.com/@williamkoehrsen/random-forest-simple-explanation> - (Acessado 13 de março, 2017).

QUORA. **How can I use a Support Vector Machine in regression-tasks-SVM** <https://www.quora.com/>- (Acessado 13 de Março, 2017).

Raschka, S. (2016). **When does deep learning work better than svms or random forests?** <http://www.kdnuggets.com/2016/04/deep-learning-vssvm-random-forest.html>. Vadivambal, R.; Jayas, D. S. *Bio-Imaging Principles, Techniques, and Applications*, CRC PRESS, Boca Raton, FL, 2016.

RIZZARDI *et al.* **Competição por recursos do solo entre ervas daninhas e culturas**. *Ciência Rural*, Santa Maria, v.31, n.4, p.707-714, 2001.

JUNIOR, Luiz C. M.; COVOLAN, José A. U. **APLICAÇÃO DE REDES NEURAIIS PROFUNDAS PARA DETECÇÃO E CLASSIFICAÇÃO DE PLANTAS DANINHAS E SEU ESTADO DA ARTE**.

Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., Berg, A. C., and Fei-Fei, L. (2015). **ImageNet Large Scale**

SANTOS, F.A. **Redes Neurais Convolucionais Profundas na Detecção de Plantas Daninhas em Lavoura de Soja**. Tese de Mestrado. Universidade Federal do Mato Grosso do Sul. Mar, 2017.

Visual Recognition Challenge. *International Journal of Computer Vision (IJCV)*, 115(3):211–252.

VASCONCELOS, M. C.C. **Interferência de Plantas Daninhas sobre Plantas Cultivadas**. Universidade Federal de Campina Grande. V. 8, n. 1, p. 01-06, jan - mar, 2012.