

CENTRO UNIVERSITÁRIO DE ANÁPOLIS – UniEVANGÉLICA
BACHARELADO EM ENGENHARIA DE COMPUTAÇÃO

ANA CAROLINY AMÂNCIO VEIGA
LUCAS GALVÃO LIMA

**RECONHECIMENTO AUTOMÁTICO DE PIVÔ DE IRRIGAÇÃO:
UMA ABORDAGEM COM DEEP LEARNING**

ANÁPOLIS

2019

ANA CAROLINY AMANCIO VEIGA
LUCAS GALVÃO LIMA

**RECONHECIMENTO AUTOMÁTICO DE PIVÔ DE IRRIGAÇÃO:
UMA ABORDAGEM COM DEEP LEARNING**

Trabalho de Conclusão de Curso II apresentado
como requisito parcial para a conclusão do curso
de Bacharelado em Engenharia de Computação do
Centro Universitário de Anápolis -
UniEVANGÉLICA.

Orientador(a): Ma. Natasha Sophie Pereira

ANÁPOLIS

2019

ANA CAROLINY AMÂNCIO VEIGA
LUCAS GALVÃO LIMA

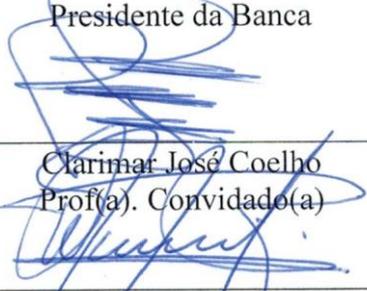
**RECONHECIMENTO AUTOMÁTICO DE PIVÔ DE IRRIGAÇÃO UMA
ABORDAGEM COM DEEP LEARNING**

Trabalho de Conclusão de Curso II apresentado como requisito parcial para a obtenção de grau do curso de Bacharelado em Engenharia de Computação do Centro Universitário de Anápolis - UniEVANGÉLICA.

Aprovado(a) pela banca examinadora em 3 de dezembro de 2019, composta por:



Natasha Sophie Pereira
Presidente da Banca



Clarimar José Coelho
Prof(a). Convidado(a)

William Pereira dos Santos Júnior
Prof(a). Convidado(a)

AGRADECIMENTOS

Agradecemos primeiramente a Deus por nos conceder a oportunidade de ingressar em um ensino superior e nos proporcionar disposição, saúde e persistência para concluir mais essa etapa em nossas vidas. Sem Deus a frente de tudo, toda a nossa dedicação seria em vão.

Agradecemos aos nossos pais Marly da Veiga, Tecio Amancio, Leila Ferreira, Jaime de Paula pela força, apoio e compreensão da nossa ausência para dedicação aos estudos durante toda essa trajetória. Sem o amor e apoio emocional de vocês, nada disso seria possível.

Um agradecimento especial a professora e amiga Natasha Sophie Pereira pela excelência dedicação e paciência para nos guiar durante esse processo de desenvolvimento deste Trabalho de Conclusão de Curso. Ao professor Clarimar José Coelho e Nilton Correia da Silva que não mediram esforços para nos auxiliar durante o desenvolvimento deste trabalho.

Aos colegas de curso que contribuíram positivamente no decorrer da graduação, nosso muito obrigado!

*That he not busy being born
Is busy dying.*

- Bob Dylan

RESUMO

Atualmente os métodos de reconhecimento de padrões em imagens dispõem de tecnologias que englobam a Inteligência Artificial para extração de informação, se baseiam em modelos computacionais e matemáticos que visam a extração de determinadas informações a partir da análise de dados. Este trabalho objetiva mostrar por meio do uso de técnicas de *Deep Learning*, uma Rede Neural especializada em reconhecimento automático de Pivôs de Irrigação com imagens obtidas pelo INPE (Instituto Nacional de Pesquisa Espaciais). A construção da ferramenta de identificação dos padrões nas imagens busca melhorar e acelerar os métodos tradicionais para identificar o objeto analisado. Neste estudo foi proposto uma abordagem com redes neurais convolucionais para identificação de Pivôs de Irrigação. De acordo com os resultados obtidos no treinamento em primeira instância obteve-se uma acurácia de 93,75% de acerto com a arquitetura baseada na *AlexNet*. O experimento foi aplicado à região de Paracatu - Minas Gerais cobrindo uma área de 5.348 km². Os resultados de testes obtidos, servirão como modelo para se quantificar a taxa de aumento dos mecanismos de Pivôs de irrigação em diversas áreas do território brasileiro que tenham Pivôs de Irrigação ou não.

Palavras chave: Redes Neurais Artificiais. Análise de Imagens. Reconhecimento de Padrões. Geoprocessamento.

ABSTRACT

Currently, the methods of pattern recognition in images with technologies that include Artificial Intelligence for information extraction are based on computational and mathematical models that aim at the extraction of certain information from data analysis. This work aims to show through the use of Deep Learning techniques, a Neural Network specialized in automatic recognition of Irrigation Pivot with images obtained by INPE (National Institute of Space Research). The construction of the tool to identify patterns in the images seeks to improve and accelerate the traditional methods to identify the analyzed object. In this study it was proposed an approach with convolutional neural networks to identify irrigation pivots. According to the results obtained in the training in the first instance, an accuracy of 93.75% was obtained with the architecture based on AlexNet. The experiment was applied to the region of Paracatu - Minas Gerais covering an area of 5,348 km². The test results obtained will serve as a model to quantify the rate of increase of the irrigation pivots mechanisms in several areas of the Brazilian territory that have irrigation pivots or.

Keywords: Artificial Neural Networks. Image Analysis. Pattern Recognition. Geoprocessing.

LISTA DE ILUSTRAÇÕES

Figura 1. Pivô de irrigação central.	20
Figura 2. Pivôs de irrigação Captados por Imagens de Satélites.....	20
Figura 3. Estrutura de um Neurônio Biológico.	24
Figura 4. Estrutura de um Neurônio Artificial.	25
Figura 5. Modelo Perceptron.....	27
Figura 6. Gráficos (a) Sigmóid, (b) Tanh e (c) ReLU.....	29
Figura 7. Estrutura de uma CNN.....	31
Figura 8. Transferência de aprendizado.	33
Figura 9. Modelo de Matriz de Confusão.....	35

LISTA DE ABREVIATURAS E SIGLAS

AI	Inteligência Artificial, do inglês <i>Artificial Intelligence</i>
ANA	Agência Nacional de Águas
ANN	Redes Neurais Artificiais, do inglês <i>Artificial Neural Network</i>
API	Interface de Programação de Aplicativos, do inglês <i>Application Programming Interface</i>
BIL	Banda Intercalada por Linhas, do inglês <i>Band Interleaved by Lines</i>
BIP	Banda Intercalada por Pixels, do inglês <i>Band Interleaved by Pixel</i>
BSQ	Banda em Sequência, do inglês <i>Band SeQuential</i>
CNN	Rede Neural Convolutacional, do inglês <i>Convolutional Neural Network</i> .
DCNN	Rede Neural Convolutacional Profunda, do inglês <i>Deep Convolutional Neural Network</i>
DL	Aprendizado Profundo, do inglês <i>Deep Learning</i>
GD	Gradiente Descendente, do inglês <i>Gradient Descent</i>
GPS	Sistema de Posicionamento Global, do inglês <i>System Position Global</i>
ha	Hectare
Hz	Hertz
INPE	Instituto Nacional de Pesquisa Espaciais
m	Metros
ML	Aprendizado de Máquina, do inglês <i>Machine Learning</i>
nm	Nanômetro
PI	Pivô de Irrigação
ReLU	Unidade Linear Restrita, do inglês <i>Restricted Linear Unit</i>
SVM	Máquina de Vetor de Suporte, do inglês <i>Support Vector Machine</i>
TL	Transferência de aprendizagem, do inglês <i>Transfer Learning</i>
XML	Linguagem de Marcação Extensiva, do inglês <i>Extensible Markup Language</i>

LISTA DE SÍMBOLOS

μm	Micrômetro – uma grandeza física de comprimento
\mathbb{R}	Conjunto dos números reais
Σ	Somatório
S_c	Função sigmóide
\geq	Maior igual
$<$	Menor
b	Bias
δ	Delta
∇	Nabla
σ	Sigma
Θ	Teta

SUMÁRIO

1. Introdução	13
1.1. Problema	13
1.1.1. <i>Central</i>	13
1.1.2. <i>Problemas Norteadores</i>	14
1.2. Justificativa	14
1.3. Objetivos	15
1.3.1. <i>Objetivo Geral</i>	15
1.3.2. <i>Objetivos Específicos</i>	15
2. Fundamentação Teórica	16
2.1. Imagens de satélite	16
2.2. Obtenção de Imagens	16
2.3. Bandas Espectrais	17
2.4. Formato de Dados das Imagens de Sensoriamento Remoto	17
2.5. Visualização de Imagens Digitais	18
2.6. Padrões	18
2.7. Pivô de irrigação	19
2.8. Inteligência Artificial	21
2.9. Machine Learning	21
2.10. Redes Neurais Artificiais	22
2.10.1. <i>Neurônio Biológico</i>	23
2.10.2. <i>Neurônio artificial</i>	24
2.10.3. <i>Perceptron</i>	26
2.10.4. <i>As Camadas em Redes Neurais</i>	27
2.11. Deep learning	29
2.12. Redes Neurais Convolucionais	30
2.13. Transferência de aprendizagem	32
2.14. Gradiente Descendente	33
2.15. Backpropagation	34
2.16. Métricas	34
2.16.1. <i>Acurácia</i>	34
2.16.2. <i>Matriz de Confusão</i>	35
2.16.3. <i>Precisão</i>	35
2.16.4. <i>Recall</i>	35
2.16.5. <i>F1 Score</i>	36
2.17. Tecnologias	36

2.17.1.	<i>Linguagem Python</i>	36
2.17.2.	<i>Bibliotecas</i>	36
3.	Desenvolvimento	37
3.1.	Obtenção e Pré-Processamento das Imagens	37
3.2.	Treinamento da Rede	38
3.3.	Validação da Rede	38
3.4.	Resultados Obtidos	38
4.	Considerações Finais	40
4.1.	Sugestão de Trabalhos Futuros	40
	Referências	42

1. INTRODUÇÃO

1.1. Problema

1.1.1. Central

O Brasil é um país referência quando o assunto é agricultura. A irrigação é uma tecnologia imprescindível no processo de aumento da produção de bens agrícolas (TESTEZLAF, 2017). Existem os mais variados tipos de laboração de solo usando irrigação, porém, o objetivo é sempre a busca do aumento na produtividade de alimentos. Atualmente, mais da metade da população mundial depende de alimentos produzidos por áreas irrigadas (MANTOVANI; BERNARDO; PALARETTI, 2009). A exploração dos recursos tem sido usada de forma excessiva para a produção de alimentos em todas as partes do mundo. Para Setti *et al.* (2000) a crescente demanda de água está ocasionando problemas e esgotando os recursos hídricos do planeta.

Em 2014, Landau e Guimarães realizaram um levantamento junto a Agência Nacional de Águas (ANA), e conseguiram determinar que a irrigação brasileira estava crescendo a taxas médias anuais entre 4,4% e 7,3% desde a década de 1960 (LANDAU; GUIMARÃES, 2014). A tendência de escassez dos recursos hídricos, em contraponto à sua crescente demanda, tem causado sérios conflitos pelo uso da água (GUIMARÃES; LANDAU, 2011). Com o crescimento exponencial mostrado dos sistemas de irrigação por pivô central torna-se necessário a identificação para uma melhor fiscalização dos órgãos competentes.

O trabalho de reconhecimento de pivôs de irrigação em imagens de satélites atualmente é feito de forma manual por especialistas em geoprocessamento, o que demanda conhecimentos específicos e muito tempo. Conforme Braga e Oliveira (2005), que em um de seus estudos mostram que foi feita a classificação visual das áreas irrigadas por pivô central. Landau, Guimarães e Reis (2013) mostram que as áreas irrigadas por pivôs centrais no Estado de Goiás e no Distrito Federal foram levantadas através da identificação visual. Landau, Guimarães e Sousa (2016) apresentam que foram mapeadas as áreas irrigadas por pivôs centrais em 2013 na Região do MATOPIBA, através da identificação visual. De mesmo modo, Martins *et al.* (2016), apresentam estudo em que a identificação dos pivôs centrais foi realizada diretamente sobre o monitor do computador através de detecção visual.

O conhecimento das áreas ocupadas pela agricultura irrigada, bem como do regime de uso dessas áreas para a produção agrícola, representa informações importantes para estimar a demanda de água para a agricultura irrigada em cada região, subsidiando o gerenciamento adequado considerando os múltiplos usos da água disponível por bacia hidrográfica (LANDAU; GUIMARÃES, 2014).

1.1.2. Problemas Norteadores

- Como desenvolver e treinar uma rede Neural para identificação de padrões em imagens de satélite?
- Como determinar se a Rede Neural Artificial, é eficiente e eficaz para resolução do problema em questão?
- Como avaliar a eficácia e eficiência da Rede Neural que será desenvolvida é adequado para solução do problema?

1.2. Justificativa

O uso da tecnologia está intimamente relacionado as mais diversas áreas das ciências já conhecidas pelo homem. Dentre as diversas áreas de aplicabilidade da tecnologia da informação está o reconhecimento de padrões que tem como pilar analisar através de dados pré-definidos e ocorrências de conjuntos informações. Para Rezende (2003) um sistema de aprendizado é um programa de computador que toma decisões baseado em experiências acumuladas por meio de solução bem-sucedida de problemas anteriores.

Na perspectiva de *software*, muito se tem avançado no sentido de desenvolvimento de tecnologias para a agricultura, que posteriormente traz melhorias significativas de informações terrestres, como o as plataformas *ArcGIS*, *Bentley*, *Google Earth*, *MapInfo* dentre outros. Dificuldades como: identificação manual de padrões, significativo tempo gasto para obtenção de informações simples, pesquisa, especializações de equipes, além de demandar mais recursos financeiros, fiscalização de órgãos governamentais quanto a utilização de água, etc. Segundo Landau e Guimarães (2014) o mapeamento das áreas irrigadas permite a análise da oferta e demanda de água nas bacias hidrográficas e serve de referência para a outorga de instalação de novos equipamentos de irrigação e o gerenciamento de uso em períodos críticos de estiagem.

O desenvolvimento de uma aplicação que reconheça automaticamente pivôs de irrigação, mitigaria o tempo, recursos financeiros, facilitaria o controle sobre a produção de

determinados alimentos, auxiliando na fiscalização quanto à outorga d'água. Os problemas de escassez hídrica no Brasil decorrem, fundamentalmente, da combinação do crescimento exagerado das demandas localizadas e da degradação da qualidade das águas (SETTI et al., 2000). O Brasil por ser um país com diversos climas, possui algumas regiões com maior disponibilidade de água e outras desprovidas de tais recursos.

O conhecimento das áreas ocupadas pela agricultura irrigada, bem como do regime de uso dessas áreas para a produção agrícola, representa informações importantes para estimar a demanda de água na agricultura irrigada em cada região, subsidiando o gerenciamento adequado considerando os múltiplos usos da água disponível por bacia hidrográfica (LANDAU; GUIMARÃES, 2014).

1.3. Objetivos

1.3.1. Objetivo Geral

Desenvolver uma Rede Neural para reconhecimento automático de pivôs de irrigação em imagens captadas por satélites.

1.3.2. Objetivos Específicos

- Adquirir imagens captadas do satélite Landsat-8 em RGB.
- Desenvolver uma Rede Neural Artificial especializada no reconhecimento de Pivôs de irrigação;
- Treinar a Rede Neural Artificial desenvolvida.
- Verificar a acurácia da Rede Neural Artificial desenvolvida.

2. FUNDAMENTAÇÃO TEÓRICA

2.1. Imagens de satélite

Os satélites artificiais são objetos criados pelo homem que se deslocam em círculos na órbita da Terra ou de outro objeto, sendo assim seu caminho é chamado de órbita. Segundo Florenzano (2002), o satélite artificial permanece em órbita devido à aceleração da gravidade da Terra e à velocidade em que se desloca no espaço, que depende da altitude da sua órbita.

Com o grande avanço dos mais variados meios tecnológicos, é perceptível o quanto os satélites artificiais fazem parte do cotidiano do ser humano, pois estão presentes nas telecomunicações desde a internet, chamadas telefônicas e diversos meios de comunicação. O desenvolvimento de satélites artificiais teve início na década de 1950 com o lançamento do *Sputnik-1*, no dia 4 de outubro de 1957, pela antiga União das Repúblicas Socialistas Soviéticas, URSS (FLORENZANO, 2002).

Sensoriamento remoto é uma tecnologia utilizada em satélites artificiais que é capaz de identificar a radiação eletromagnética transmitida pela energia solar refletida na superfície terrestre a fim de gerar dados para compreensão de determinadas áreas do nosso planeta. Esses dados são transformados em imagens, gráficos e entre outros tipos (FLORENZANO, 2002).

2.2. Obtenção de Imagens

As imagens obtidas através do sensoriamento remoto são representações matriciais dos valores de intensidade da energia que é refletida por objetos existentes na terra (FLORENZANO, 2011). As imagens captadas pelos satélites, permitem uma análise do meio ambiente que possibilita um estudo regional e integrado com vários campos. Essas análises mostram os ambientes e a sua transformação e também destacam os impactos causados por fenômenos naturais como as inundações e a erosão do solo (frequentemente agravados pela intervenção do homem) e antrópicos, como os desmatamentos, as queimadas, a expansão urbana, ou outras alterações do uso e da ocupação da terra (FLORENZANO, 2002).

As imagens captadas pelos satélites são caracterizadas por quatro resoluções que indicam seu tipo que são elas: resolução espacial, resolução espectral, resolução radiométrica e a resolução temporal. Florenzano (2011), define as quatro resoluções da seguinte maneira:

- A Resolução Espacial define o tamanho do menor objeto identificado na imagem detectada pelo sensor.
- Resolução Espectral possibilita a classificação da sensibilidade espectral de cada sensor, ou seja, quais faixas do espectro eletromagnético o sensor pode captar.
- Resolução Radiométrica classifica a intensidade da energia fornecida pelos objetos contidos nas imagens, especificando para cada um a quantidade dos valores de cinza utilizados para sua representação.
- Resolução Temporal é a resolução que define a frequência em que o sensor obtém as imagens em uma mesma área

2.3. Bandas Espectrais

Os objetos presentes na terra refletem, absorvem e transmitem radiações eletromagnéticas de acordo com suas características físico-químicas. Tais radiações são captadas pelos sensores de acordo com seus comprimentos de ondas. Como cada sensor capta informações em uma certa faixa do espectro eletromagnético e gera uma imagem (banda) naquela faixa, uma imagem de satélite é composta por várias bandas. As variações de energia captada representadas em cada banda formam o que é chamado de curva espectral do alvo. As curvas espectrais de cada objeto variam, e a partir dessa variação é possível determinar o tipo de objeto que está sendo representado na imagem (PEREIRA, 2014).

2.4. Formato de Dados das Imagens de Sensoriamento Remoto

As imagens obtidas pelos sensores de satélites são geradas em formato de matriz e representadas por uma combinação de linhas e colunas com as bandas da imagem. O armazenamento pode ser feito em três formatos BSQ, BIL e BIP. De acordo com Richards e Jia (2006), cada um destes formatos é definido da seguinte forma:

- BSQ (Banda em Sequência, do inglês *Band SeQuential*) é um formato capaz de organizar os dados de cada banda da imagem em sequência.
- BIL (Banda Intercalada por Linhas, do inglês *Band Interleaved by Lines*) arranja os dados das linhas de cada banda em ordem, repetindo esse processo de acordo com a quantidade de linhas que cada banda contém.
- BIP (Banda Intercalada por Pixels, do inglês *Band Interleaved by Pixel*) nesse formato a organização dos dados é feita de modo que cada pixel é armazenado

em sequência para todas as bandas da imagem, repetindo o processo para os demais pixels de cada linha.

É possível observar os três formatos básicos dos dados e perceber sua interação com as dimensões espacial, espectral e radiométrica no armazenamento da imagem em disco. Com relação ao tamanho da imagem final, este é proporcional ao tamanho das dimensões, sendo assim, as imagens de satélites, em geral, são arquivos grandes.

2.5. Visualização de Imagens Digitais

Para a visualização de imagens digitais é realizado um pré-processamento de sensores remotos, que são capazes de tratar os dados brutos calibrando e realizando a radiometria da imagem, removendo ruídos e corrigindo as distorções geométricas que podem ocorrer durante a obtenção das imagens.

O georreferenciamento é um procedimento onde são realizadas as correspondências entre as coordenadas de linhas e colunas da imagem e as coordenadas geográficas de latitude e longitude, fazendo ajustes das imagens de acordo com a localização do terreno. De modo que cada pixel da imagem passe a corresponder a um ponto da superfície da terra, conhecido como elipsoide de revolução (FLORENZANO, 2011).

Em uma imagem digital cada pixel contém um valor que é chamado de valor digital e representa o nível de energia obtida pelo sensor em um determinado ponto da imagem (PEREIRA, 2014). É possível observar que quanto mais baixos os valores, mais o alvo absorve energia, esses valores correspondem aos níveis de cinza escuros na imagem, e os pixels com os valores mais altos correspondem aos níveis de cinza claros, pois o alvo reflete mais e absorve menos energia (FLORENZANO, 2011).

2.6. Padrões

O reconhecimento de padrões é uma técnica comumente utilizada tanto para sistemas computadorizados como pelo próprio ser humano. O ser humano possui a capacidade única de reconhecer padrões, quando observa algo faz a coleta de informações para identificar, associar e reconhecer formas sons ou conceitos (CERA, 2005). Podemos entender como padrão uma sequência lógica de informações organizadas a tal ponto que remetem alguma similaridade. Haykin (2001) explica que um padrão pode ser definido como um processo pelo qual um padrão pode ser atribuído a uma classe dentre um número pré-

determinado de classes. Em pivô de irrigação, segue-se um padrão de círculos e meio círculo em quase sua totalidade.

2.7. Pivô de irrigação

O sistema de irrigação por pivô central teve seu surgimento em 1952 no Estado do Colorado – EUA, mas foi apenas a partir de 1960 que seu uso foi solidificado (SOUZA, 2001). Um sistema de irrigação por pivô central, é um mecanismo composto por um braço mecânico horizontal fixado a um eixo central, com tubulações que irrigam por aspersão em movimentos circulares determinadas áreas. Conforme Pereira (2004), para suportar o vão livre do pivô entre torres adjacentes, existe uma estrutura de treliças e tirantes que mantém a tubulação a uma determinada altura do solo (4 a 5 metros) compatível com as culturas a serem irrigada. Para Silva e Azevedo (1998), o movimento da estrutura é feito por motores instalados em cada torre para acionamento dos motores-redutores das rodas. A Figura 1 ilustra um pivô de irrigação central.

O dimensionamento do pivô impacta diretamente na quantidade de área que será irrigada. Silva e Azevedo (1998) explicam que o comprimento lateral do sistema de irrigação por Pivô Central é bastante variado, dependendo da necessidade do produtor, das características topográficas e das dimensões da área a ser irrigada. Geralmente esse tipo de irrigação é muito utilizado em grandes lavouras que demandam grandes quantidades de água, e de acordo com Pereira (2004), sistemas de irrigação por pivô central podem irrigar grandes áreas, geralmente superiores a 100 ha (hectares). Os pivôs mais modernos, irrigam em torno de 50 a 130 ha.

Os pivôs centrais de irrigação apesar de todos os benefícios disponibilizados a partir da irrigação para produção de bens de consumo, ainda trazem em sua bagagem diversos danos ao meio ambiente. O Brasil é privilegiado em relação aos mananciais de água doce, respondendo a quase 43% de toda a disponibilidade mundial, cuja parte significativa dessa disponibilidade está concentrada na Bacia Amazônica (BRAGA; OLIVEIRA, 2005).

A instalação desses mecanismos próximos a mananciais, podem acarretar diversos problemas aos recursos hídricos em determinadas regiões. Braga e Oliveira (2005) explicam que os recursos hídricos, apesar de renováveis, podem se esgotar devido à alta taxa de exploração. O uso de defensivos agrícolas em excesso para a contenção de plantas daninhas também acarreta uma série de danos ambientais. Segundo Testezlaf (2017) esta técnica representa um risco elevado para as fontes de água, devido ao seu alto potencial de

contaminação no caso de uma parada inesperada do sistema ou de vazamentos, fazendo com que a solução química injetada no sistema retorne à fonte ou contamine o solo.

Figura 1. Pivô de irrigação central.



Fonte: Site Valley Irrigation (2019).

Martins *et al.* (2016) explicam que os pivôs ocupam, principalmente, as proximidades das rodovias, além de gerarem enorme consumo de água e, conseqüentemente, um aumento na pressão sobre os recursos hídricos. Os autores ainda mencionam que conhecer o avanço e a espacialização dos pivôs é de suma importância para propor ações e medidas mitigadoras que possam contribuir para minimizar a pressão sobre os recursos hídricos. As Figura 2 e apresenta pivôs de irrigação captados por imagens de satélites.

Figura 2. Pivôs de irrigação Captados por Imagens de Satélites.



Fonte: Site EngeSat (2019).

2.8. Inteligência Artificial

A Inteligência Artificial (AI, do inglês *Artificial Intelligence*) é definida por realizar estudos do comportamento inteligente humano e de outros animais, podendo ser aplicada em sistemas a fim de solucionar desde problemas simples até os mais complexos (COPPIN, 2010). Teve sua origem quando os pesquisadores procuravam entender como funcionavam os processos de visão, lembranças e raciocínio do cérebro humano (GOMES, 2010).

Pode-se dizer que o primeiro grande trabalho reconhecido como IA foi realizado por Warren Macculloch e Walter Pitts em 1943 (GOMES, 2010). Para Russell e Norvig (2003), a história da AI inicia durante os anos 40 e seu estudo se prolonga até os dias de hoje. Com o passar dos anos foram surgindo as linhas e estudos da AI, como as Redes Neurais Artificiais (ANN, do inglês *Artificial Neural Networks*) que imitam as redes neurais do cérebro humano.

2.9. Machine Learning

O aprendizado de máquina (ML, do inglês *Machine Learning*) está diretamente conectado com a inteligência artificial porque se o sistema tem a capacidade de realizar tarefas específicas pode ser considerado inteligente (COPPIN, 2010). O mundo está envolto de tecnologias que objetivam facilitar a vida das pessoas de maneira direta ou indireta como os aplicativos para navegação usando o Sistema de Posicionamento Global (GPS, do inglês *System Position Global*), sistemas de recomendações, sistemas inteligentes detectores de doenças, humor, predição de dados entre outros, são sistemas inteligentes que objetivam a melhoria de uma tarefa. O ML foi criado para que o sistema utilize as informações que foram recebidas para realizar tarefas sem que haja intervenção humana (FERNANDES et al., 2018).

A análise de dados objetiva responder/resolver questões a partir de hipóteses de dados pré-estabelecidos. Aprendizado de Máquina pode ser definido como um conjunto de métodos computacionais que utilizam da experiência adquirida para melhorar seu desempenho na realização de tarefas, ou fazer previsões consistentes sobre informações não conhecidas (MITCHELL, 1997). Para Kohavi e Provost (1998), *Machine Learning* é o campo do estudo científico que se concentra em algoritmos de indução e em outros algoritmos que podem ser ditos "aprender".

Do ponto de vista computacional, aprender é raciocinar em cima de uma hipótese como um ser humano faria em algumas situações que demandariam raciocínio lógico ou tomada de decisão. Fernandes *et al.* (2018) explicam que os processos de raciocínio humano são simulados pelas ANN que analisam todas as possibilidades culminando em uma conclusão que expõe as soluções que são mais pertinentes de acordo com o processo solicitado. De modo geral os sistemas adquirem experiência por meio de informações já analisadas, de modo que, quanto mais dados são analisados pelo sistema, mais ele aprende sobre determinada informação.

A principal função do ML é “aprender” a partir de dados. Para auferir tais objetivos, diversas técnicas foram desenvolvidas ao longo dos anos que podem ser engajadas como subárea do ML, por exemplo as Redes Neurais Artificiais e o Aprendizado Profundo (DL, do inglês *Deep Learning*).

2.10. Redes Neurais Artificiais

O cérebro humano possui complexidade de alto nível, processamento não-linear e paralelo, além da capacidade de organização de estruturas de neurônios e alta velocidade de processamento, o que levou ao desenvolvimento das Redes Neurais Artificiais para simular seu comportamento (HAYKIN, 2001). O cérebro humano possui aproximadamente 100 bilhões de neurônios que se comunicam entre si por meio de sinapses, formando uma rede neural que é chamada de rede neural biológica. Essa rede é responsável pela capacidade de processar e armazenar informações no cérebro (FINOCCHIO, 2014).

Uma rede neural é um aglomerado de diversos neurônios conectados pelos dendritos e terminais sinápticos. Ferneda (2006) diz que combinando diversos neurônios forma-se uma rede neural artificial. Haykin (2001) define que uma rede neural é um processador paralelo distribuído, com uma vocação natural para armazenar o conhecimento experimental, tornando-o disponível para uso posterior. O processo de aprendizado é uma das propriedades mais importantes das redes neurais e esse processo é realizado através de etapas interativas com ajustes de acordo com os pesos matemáticos aplicados. O mesmo acontece quando a rede alcança um resultado generalizado para um conjunto de problemas. Os três principais paradigmas de aprendizado de máquina são: Aprendizado Supervisionado, Aprendizado não Supervisionado, Aprendizado por/com reforço, onde:

- No aprendizado supervisionado, um agente externo (professor) apresenta à rede neural alguns conjuntos de padrões de entrada e seus correspondentes padrões de saída. Portanto, é necessário ter um conhecimento prévio do comportamento que se deseja ou se espera da rede (FERNEDA, 2006). Neste método, a cognição se dá por meio de dados pré-estabelecidos.
- Para o aprendizado não supervisionado, Maia (2019) explica que é necessário que um algoritmo de reconhecimento seja capaz de encontrar similaridade entre diferentes indivíduos.
- O Aprendizado com reforço é baseado na ideia de que, se uma ação é seguida de estados satisfatórios, ou por uma melhoria no estado, então a tendência para produzir esta ação é aumentada, ou seja, é reforçada (FARIA; ROMERO, 1999).

Baseado no Sistema Nervoso humano, de sua capacidade de abstração e processamento de uma grande quantidade de informações, surgiu o conceito de Aprendizado Profundo (DL, do inglês *Deep Learning*), que é um ramo de Redes Neurais, porém, com uma quantidade maior de neurônios artificiais conectados entre si. Essa técnica possibilita a manipulação de uma grande quantidade de dados de diversos tipos como imagens, textos e voz, pois permite que a máquina perceba padrões mesmo em informações inter-relacionadas (FERNANDES et al., 2018).

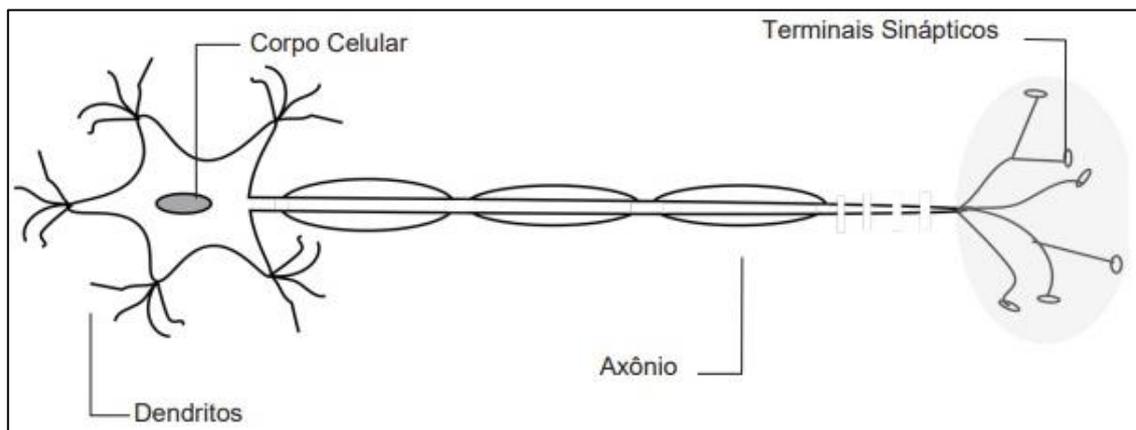
2.10.1. Neurônio Biológico

O cérebro humano ainda é o computador mais incrível e mais complexo que a ciência tem conhecimento. Ele é composto por aproximadamente 100 bilhões de neurônios. Dentro das células nervosas contém as terminações dos axônios que são responsáveis pela transmissão dos estímulos para as demais células e suas fibras tubulares são capazes de alcançar até alguns metros e a outra terminação são os dendritos que são os receptores dos estímulos que são transmitidos por diversos neurônios (FINOCCHIO, 2014). A representação mais simples de um neurônio biológico é apresentada na Figura 3.

Segundo Finocchio (2014) a rede neural é formada por um conjunto extremamente complexo de neurônios e, entre eles, a comunicação é realizada através de impulsos nervosos. No processo de aprendizagem, o neurônio biológico recebe entradas de informações por meio de impulsos nervosos pelos dendritos (dendrites). Após receber o impulso/informação é efetuada uma espécie de cálculo de peso baseado na força da conexão,

todas as entradas são somadas dentro do corpo celular. Essa soma é novamente transformada em sinal que é propagado em sentido unidirecional através dos axônios e enviado para outros neurônios através dos terminais sinápticos. O neurônio que transmite o pulso pode controlar a frequência de pulsos, aumentando ou diminuindo a polaridade na membrana pós-sináptica.

Figura 3. Estrutura de um Neurônio Biológico.



Fonte: Desenvolvido pelos autores com base em Buduma (2017).

Finocchio (2014) conceitua que os principais constituintes de um neurônio são:

- Dendritos - responsáveis por receber os estímulos transmitidos pelos outros neurônios;
- Corpo celular - responsável por coletar e combinar informações vindas de outros neurônios;
- Axônio - responsável por transmitir os estímulos para outras células (constituído de uma fibra tubular que pode alcançar até alguns metros).

A conexão/transmissão de informação entre 2 ou mais neurônios biológicos ou artificiais formam uma rede neural.

2.10.2. Neurônio artificial

A busca por um modelo computacional que simule o funcionamento das células do cérebro data dos anos 1940, com o trabalho de McCulloch e Pitts (FERNEDA, 2006). A Figura 4 demonstra a estrutura de um neurônio artificial.

A *Data Science Academy* (2017) apresenta 5 características importantes que cada um dos elementos contidos nos neurônios artificiais desempenham em sua função específica:

- i. Sinais de entrada que servirão como base para o treinamento e processamento das informações.
- ii. Pesos sinápticos que emulam o comportamento das sinapses de um neurônio biológico.
- iii. Função de soma que realiza a soma das entradas multiplicando pelos seus respectivos pesos.
- iv. Função de ativação exerce o papel de definir como o neurônio será ativado conforme o resultado obtido na função de soma.
- v. Saída que representa o resultado da análise realizada por aquele neurônio. Na maioria dos casos, um neurônio estará ligado a outros neurônios de outras camadas ou da mesma.

Um neurônio artificial pode ser definido em termos matemáticos de acordo com as equações (1) e (2)

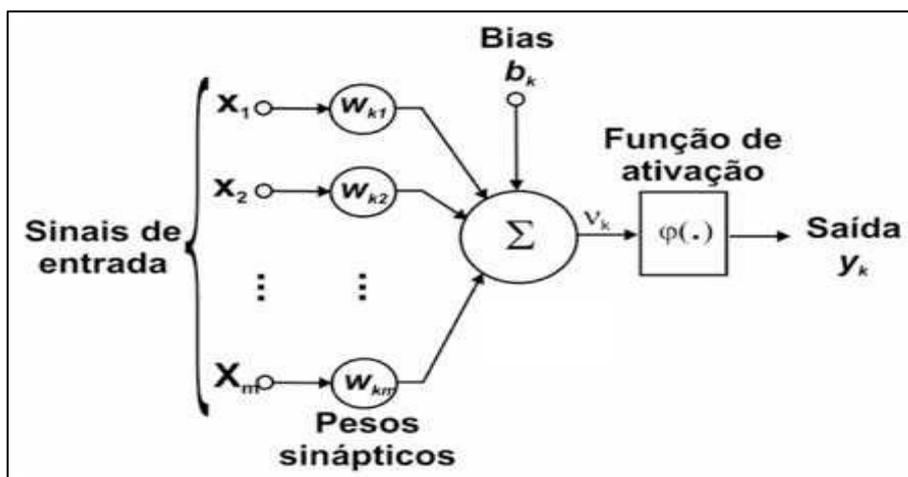
$$uk = \sum_{j=1}^n w_{kj}x_j \quad (1)$$

e respectivamente

$$yk = \varphi(uk + bk) \quad (2)$$

onde $x_1, x_2, x_3, \dots, x_{n+1}$, são sinais de entrada. $w_{k1}, w_{k2}, w_{k3}, \dots, w_{k+1}$, são pesos sinápticos do neurônio k e b_k que correspondem às bias, responsável por deslocar a função de ativação, definida por φ (FERREIRA, 2017).

Figura 4. Estrutura de um Neurônio Artificial.



Fonte: Rodrigues e Silva e Schimidt (2016).

Segundo Ferreira (2017), para constituir-se uma Rede Neural, os neurônios são agrupados em estruturas denominadas camadas. Uma Rede Neural Artificial tem como objetivo processar um conjunto de dados de calibração, inseridos na camada de entrada da rede, propagando-se por cada neurônio, o qual terá um número de entradas e uma saída (RODRIGUES E SILVA; SCHIMIDT, 2016). As redes neurais artificiais do tipo *Deep Learning* e suas camadas mostram-se como o alicerce para o tratamento de informações.

A aprendizagem profunda é um método específico de aprendizado de máquina que incorpora redes neurais em camadas sucessivas para aprender com os dados como é defendido por um de seus criadores McCulloch e Pitts (1990) demonstrando que redes neurais poderiam calcular funções aritméticas ou lógicas na sua modelagem.

2.10.3. *Perceptron*

O *perceptron* representa o modelo mais simples de uma rede neural. O modelo *Perceptron* é um classificador linear, ou seja, uma rede neural que não possui camadas ocultas. O tipo mais simples de um *perceptron* possui uma única camada de pesos conectando as entradas e saídas (SOMPOLINSKY, 2013). Um *perceptron* aprende a partir de exemplos repetitivos que lhes são apresentados e dá uma resposta como verdadeiro ou falso baseada em pesos das informações que foram apresentadas conforme a função de ativação pré-definida que é dada pela equação (3)

$$g(x) = \begin{cases} 1, & \text{se } x \geq T \\ 0, & \text{se } x < T \end{cases} \quad (3)$$

onde T é conhecido como valor limite que é usado para comparação da soma ponderada das entradas com o valor limite com o intuito de definir a saída. Neste sentido, o *perceptron* calcula a soma ponderada das entradas e pesos e submete o valor a função de ativação g , onde a informação é passada para a próxima camada de neurônios.

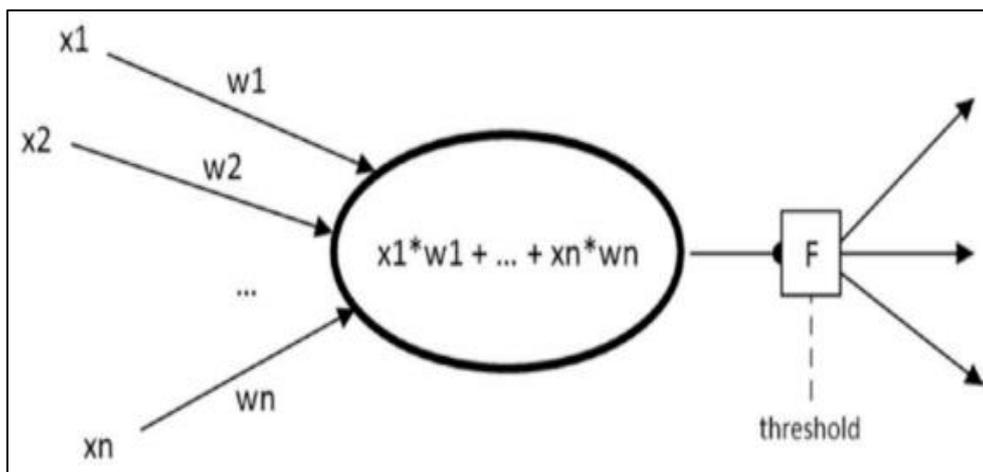
Algumas das principais características para *perceptrons* multicamadas, conforme Haykin (2008), seguem 3 recursos básicos:

- O modelo de cada neurônio na rede inclui uma função de ativação não linear que é diferenciável.
- A rede contém uma ou mais camadas que estão ocultas da entrada e dos nós de saída.

- A rede exibe um alto grau de conectividade, cuja extensão é determinada pelos pesos sinápticos da rede.

O modelo de um *perceptron* é exibido na Figura 5, onde é possível visualizar todos componentes existentes no mesmo.

Figura 5. Modelo Perceptron.



Fonte: Pérez Castaño (2018).

Os pesos sinápticos exercem o papel de armazenar os conhecimentos adquiridos. A sinapse é o nome empregado para a conexão entre os neurônios. Esta, por sua vez, forma uma rede neural onde cada *perceptron* recebe entradas onde é calculada a soma ponderada pelos pesos, que produzem uma saída 0 ou 1 mapeada através da função de ativação, passando o resultado para o próximo neurônio da próxima camada. O processo de aprendizado da MLP consiste na apresentação do conjunto de dados de treinamento, e na medida em que haja erros de classificação eles são ajustados e voltam de forma iterativa influenciando nos pesos sinápticos, a fim de minimizar os erros nas próximas iterações (SOUZA; SASSI, 2013).

2.10.4. As Camadas em Redes Neurais

Para que uma rede neural execute tarefas como reconhecimento de padrões ou modelagem de dados, deve-se treiná-la (CERQUEIRA et al., 2001). O treinamento, divide o conjunto de dados em três subconjuntos, denominados de treinamento, validação e teste.

Uma ANN é composta por diversos neurônios (*perceptrons*) conectados de modo que a saída de um neurônio esteja conectada a entrada de um neurônio da camada posterior.

Uma rede neural com uma quantidade significativa de camadas é denominada de rede neural profunda, ou *Deep Learning*, como é mais conhecida.

As camadas convolucionais consistem em um conjunto de filtros que recebem como entrada um arranjo 3D, também chamado de volume (ARAÚJO et al., 2017). Na fase de treinamento, os pesos w são escolhidos inicialmente de modo aleatório, a fim de se ter uma rede inicial a ser treinada, ou seja, otimizada para as entradas e saídas da etapa de treinamento (CERQUEIRA et al., 2001). Nesta etapa várias entradas de dados são distribuídas pelos *perceptrons* e são efetuados os cálculos dos pesos. Caso os resultados obtidos ultrapassem o valor limiar estabelecido, é propagado um sinal pelo axônio do neurônio, esse processo é chamado de função de transferência (VON ZUBEN, 2017). A saída do resultado de cada *perceptron*, é transmitida aos neurônios posteriores e estes são reforçados de maneira que haja um enlace entre eles.

As CNNs são formadas por sequências de camadas e cada uma destas possui uma função específica na propagação do sinal de entrada (ARAÚJO et al., 2017). Para cada aplicação dos modelos de camadas há tipos específicos de neurônios que possibilitam a relação por meio de funções não-lineares. Para a aplicação de funções não lineares os 3 modelos mais comuns de neurônios são o neurônio *Sigmoid*, o neurônio *Tanh*, e o neurônio de unidade linear restrita (ReLU, do inglês *Restricted Linear Unit*).

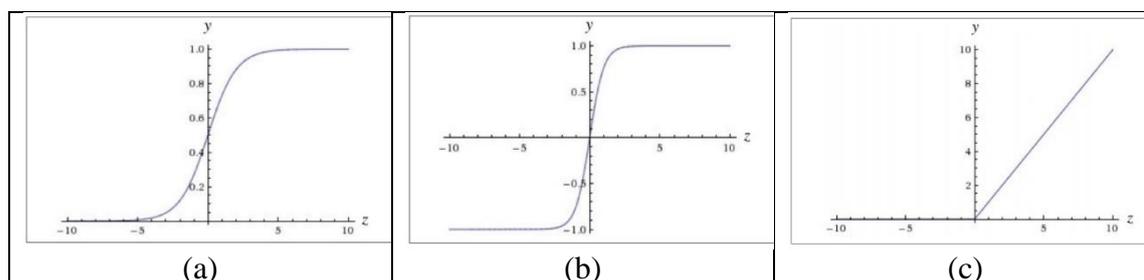
No tipo de neurônio *Sigmoid* o gráfico é representado em forma de S devido a dois fatores conforme teorizado por Buduma (2017): i) quando o *logit* (função matemática inversa de Sigmoid) é muito pequeno, a saída de um neurônio logístico é muito próxima de 0; ii) quando o *logit* é muito grande, a saída do neurônio logístico é próxima de 1. Rojas (1996) explica que uma das funções de ativação mais populares para redes de retropropagação (do inglês *backpropagation*) é o sigmóide (S_c), uma função real $S_c: \mathbb{R} \rightarrow (0, 1)$ definida pela equação (4), que está representada pela Figura 6(a).

$$S_c(x) = \frac{1}{1 + e^{-ex}} \quad (4)$$

Os neurônios que usam a função *Tanh* usam um tipo correlativo de não linearidade mas em vez de variar de 0 a 1, a saída dos neurônios varia de -1 a 1 (BUDUMA, 2017). A Figura 6(b) representa um neurônio *Tanh*. Este modelo usa a função $f(z) = \text{Tanh}(z)$ que retorna uma tangente hiperbólica de z .

ReLU é convencionalmente usada como uma função de ativação para as camadas ocultas em uma rede neural profunda (AGARAP, 2019). Em relação a função *Sigmoid* e *Tanh*, a *ReLU* apresenta uma vantagem quanto ao desempenho devido ao fato de considerar o primeiro quadrante apenas e ignorar o restante. O autor ainda cita que o modelo *ReLU* funciona por valores de limiar em 0, ou seja, $f(x) = \max(0, x)$. Simplificando, ele gera 0 quando $x < 0$ e, inversamente, gera uma função linear quando $x \geq 0$. O gráfico da função *ReLU* é representado na Figura 6(c):

Figura 6. Gráficos (a) Sigmóid, (b) Tanh e (c) ReLU.



Fonte: Buduma (2017).

2.11. Deep learning

Quando os primeiros computadores foram criados, muito se foi pensado sobre se seria possível programar um computador que tomasse decisões de maneira autônoma. Para tal desafio foi criada a Inteligência Artificial. A AI foi lançada na Conferência de *Darmouth College* em 1956 através de uma proposta de trabalho que circulava nos EUA desde 1955, e desde então o projeto estendeu-se à escala mundial (COELHO, 2012).

Desde o surgimento da AI, criaram-se modelos computacionais que servissem como auxiliares para a resolução de problemas que se tornaram cada vez mais complexos. Para Ponti e Costa (2017), técnicas de Aprendizado Profundo oferecem atualmente um importante conjunto de métodos para analisar sinais de áudio e fala, conteúdos visuais, incluindo imagens e vídeos, e ainda conteúdo textual.

O modelo computacional *Deep Learning* é uma subclasse de técnicas de *Machine Learning* que é uma subclasse de inteligência artificial. O DL é engajado no processamento de informações não lineares. Conceituando o *Deep Learning*: trata-se de um conjunto de técnicas que utilizam redes neurais artificiais profundas, com muitas camadas intermediárias entre a camada de entrada e a de saída (LECUN; BENGIO; HINTON, 2015). Buduma (2017) também explica que a aprendizagem profunda é um subconjunto de um campo mais geral

de inteligência artificial chamado aprendizado de máquina, que se baseia na ideia de aprender a partir de um exemplo.

Na prática, o *Deep Learning* é uma rede neural que possui mais camadas escondidas e que possui também um maior número de operações. A sua essência consiste em representar problemas complexos em etapas mais simples, tornando possível a extração de características de um dado analisado (SPOLTI, 2018).

Uma rede neural consiste em três ou mais camadas: uma camada de entrada, uma ou várias camadas ocultas e uma camada de saída (OL, do inglês, *output Layer*). A primeira camada é conhecida como camada de entrada (IL, do inglês, *Input Layer*) que é responsável por receber a informação de entrada, e segundo Dutra e Silva (2016), o nível de representação que a primeira camada oferece está ligado a eventos temporais provenientes dos sentidos. A segunda camada engloba o conjunto de camadas ocultas (do inglês, *Hidden Layer*), que são responsáveis por fazer o reconhecimento e filtro das informações passadas. Em análise de imagens conforme LeCun, Bengio e Hinton (2015), a segunda camada normalmente detecta motivos detectando arranjos particulares de arestas, independentemente de pequenas variações nas posições das arestas. E a última camada que se referem às camadas de saída. De acordo com Santos *et al.* (2017), a última camada das redes Convolucionais é totalmente conectada. Essa, é por sua vez, responsável por realizar a classificação dos dados a partir das conexões e sinais sinápticos conduzidos através das camadas neurais.

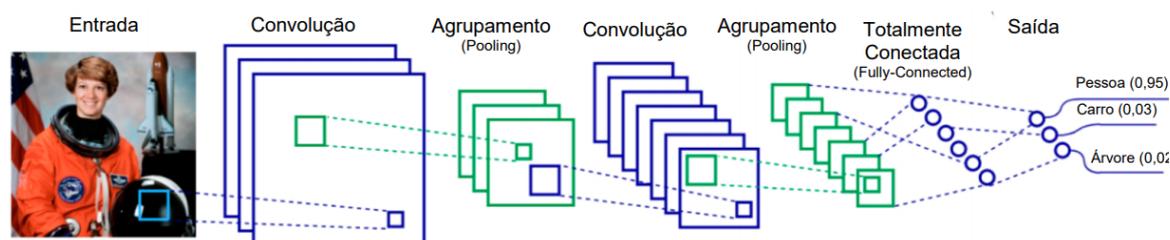
2.12. Redes Neurais Convolucionais

É evidente que uma Rede Neural deriva seu poder computacional através, primeiro, de sua estrutura distribuída massivamente paralela e, segundo, de sua capacidade de aprender e, portanto, generalizar (HAYKIN, 2008). A Rede Neural Convolucional (CNN, do inglês *Convolutional Neural Network*), é um modelo de aprendizagem amplamente utilizado, que alcançou grande desempenho em muitos estudos no campo de visão computacional, como a classificação de imagens. As CNNs são usadas para detecção de padrões no campo de processamento de informações de imagens. Algumas das vantagens consistem em: i) capacidade de extrair características relevantes através de aprendizado de transformações (*kernels*); e ii) depender de menor número de parâmetros de ajustes do que redes totalmente conectadas com o mesmo número de camadas ocultas (ARAÚJO *et al.*, 2017).

As primeiras redes neurais convolucionais foram criadas com o intuito de reconhecimento de caracteres como dígitos numéricos. A *LeNet*, proposta por LeCun *et al.* (1989), foi um dos primeiros projetos de CNN, tendo auxiliado no impulsionamento do campo de *Deep Learning*. Conforme Ponti e Costa (2017), a principal aplicação das CNNs é para o processamento de informações visuais, em particular imagens. Geralmente as técnicas usando ANN juntamente com o reconhecimento profundo são aplicadas para detecção de padrões, e semelhanças entre uma imagem baseada em padrões pré-inseridos.

Alguns dos modelos computacionais criados, foram os modelos de aprendizagem de máquina *Deep Learning* - Redes Neurais Convolucionais Profundas (DCNN, do inglês *Deep Convolutional Neural Network*). As DCNNs estão no centro dos avanços da aprendizagem profunda (DUMOULIN; VISIN, 2018). De acordo com o *Data Science Academy* (2017) a aprendizagem profunda usa técnicas de aprendizagem supervisionada, o que significa que a Rede Neural Convolucional é treinada usando dados rotulados e tratados por camadas de redes neurais. A Figura 7 mostra o modelo de uma CNN com 4 camadas.

Figura 7. Estrutura de uma CNN.



Fonte: Adaptada de Vasilef *et al.* (2018).

É perceptível, portanto, que as redes neurais convolucionais derivam o poder computacional proporcionado pela distribuição de informação a partir de camadas. Maia (2019) explica que a principal característica das CNNs deriva da capacidade de aprender padrões de imagens em vários estágios, a base do seu funcionamento parte dos conceitos de Redes Neurais Artificiais.

Para que o funcionamento das CNNs ocorra de maneira adequada, Maia (2019) explica que diversas células simples de processamento interconectadas, chamadas neurônios, devem produzir uma série de ativações em valor real. A construção de uma Rede Neural parte da base de que ela deve ser composta por neurônios conectados que trocam ou não informações. Para Farias (2011), Redes Neurais são estruturas distribuídas, formadas por grande quantidade de unidades de processamento (os neurônios) interconectados.

2.13. Transferência de aprendizagem

A Transferência de Aprendizagem (TL, do inglês *Transfer Learning*) na classificação de imagens, consiste em usar os vetores de características gerados por uma Rede Neural previamente treinada a partir de pesos sinápticos na relação de padrões (AGUIAR NETO, 2017). A tarefa de classificação de imagens aborda a identificação da presença de uma categoria em uma determinada imagem, uma tarefa complexa, exigindo a capacidade de aprender um modelo geral de um conjunto de amostras de treinamento (CARVALHO, 2015).

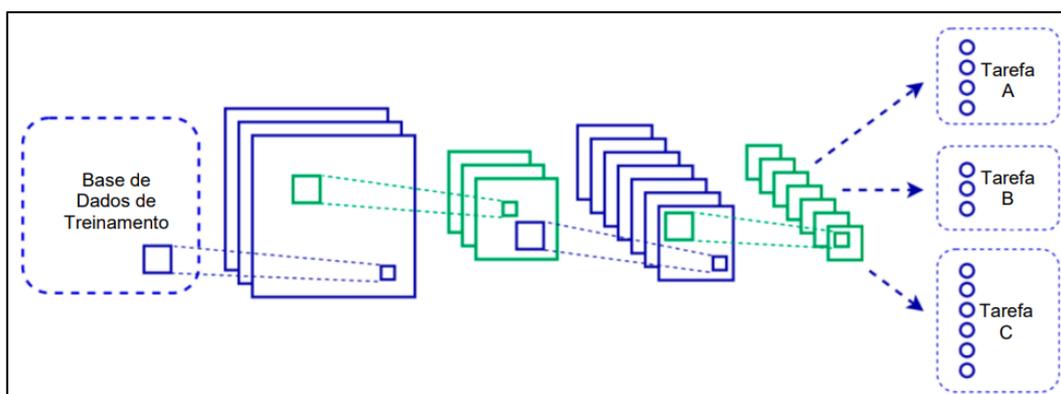
No processo de TL, primeiramente é treinada uma rede básica em cima de um conjunto de dados e tarefa e então, os recursos aprendidos são redirecionados/transferidos para a segunda camada de destino. Esse processo se repete tendendo a funcionar se os recursos forem gerais, significado adequado para as tarefas de base e de destino, em vez de específico para a tarefa base (YOSINSKI et al., 2014).

Yosinski *et al.* (2014) ainda explicam que quando o conjunto de dados de destino é significativamente menor que o conjunto de dados base, a transferência de aprendizado pode ser uma ferramenta poderosa para permitir o treinamento de uma grande rede de destino sem *overfitting*. O processo de transferência de aprendizado engloba: treinar a rede básica, copiar as camadas para que as camadas posteriores sejam inicializadas. Diversos métodos podem ser aplicados neste processo de TL, um dos mais conhecidos é a retropropagação, ou comumente conhecida como *Backpropagation*.

Uma estratégia simples para transferir conhecimento é fixar os pesos até uma camada escolhida da rede e, em seguida, reformular e treinar novamente as camadas restantes para a nova tarefa (CARVALHO, 2015). A estratégia mostrada foca em obter um maior controle sobre o processo de transferência de aprendizagem onde é possível escolher níveis de aprendizagem para vetores distintos como é mostrado por Yosinski *et al.* (2014). O processo abordado pelos autores mostra que são necessárias camadas fixas, e saída da última camada fixa para que esse vetor de suporte tenha o recurso de classificador diferente como uma SVM (Máquina de Vetor de Suporte, do inglês *Support Vector Machine*) ao final da camada da rede. Apesar de todos os recursos, classificadores e modelos existentes, Zou *et al.* (2019) explicam que a transferência de aprendizagem alivia a necessidade de uma quantidade enorme de instâncias para o treinamento de modelo.

A Figura 8 mostra como a transferência de aprendizado funciona. Neste exemplo, é possível salientar algumas conclusões. Redes neurais profundas são eficientes para dados organizados hierarquicamente como imagens (pixel, linhas, bordas, regiões, etc.) e textos (quando organizados por caracteres, palavras, frases, etc.) são alguns exemplos. No contexto geral, o exemplo mostrado na Figura 8 representa camadas onde serão definidos, de maneira automática, quais dados devem ser selecionados para o treinamento tornando as camadas mais abstratas e menos sensíveis a ruídos (VASILEV et al., 2019).

Figura 8. Transferência de aprendizado.



Fonte: Adaptada de Vasilev et al. (2019).

2.14. Gradiente Descendente

O aprendizado é o resultado de muitas interpretações de um determinado conjunto de exemplos de treinamento. Segundo Haykin (2001), durante o treinamento da rede neural, os vários padrões de entrada e suas correspondentes saídas desejadas são apresentados à ANN, de modo que os pesos são corrigidos iterativamente pelo algoritmo de gradiente descendente para minimizar a soma dos erros quadrados. Deste modo o modelo Gradiente Descendente (GD, do inglês *Gradient Descent*) baseia-se na aproximação de pesos e bias de modo que a saída se aproxime de $y(x)$ para todas as entradas de treinamento x . Para execução do modelo GD Neapolitan (2018) propôs a função apresentada na equação (5):

$$C(w, b) = \frac{1}{2n} \sum_x ||y(x) - a||^2 \quad (5)$$

onde, w representa a coleta de todos os pesos da rede e b todas as bias, n está representando o número de entradas, a e x representa todas as entradas de treinamento.

2.15. Backpropagation

O *Backpropagation*, também chamado de aprendizado por retropropagação, é um algoritmo semelhante ao algoritmo do Gradiente Descendente, e do ponto de vista de análise é usado para descobrir o menor valor de erro contido na rede. Neapolitan (2018) explica que as equações de retropropagação fornecem uma maneira de calcular o gradiente do custo de uma função. O autor ainda mostra explicitamente as nomenclaturas usadas para o algoritmo de *Backpropagation*, que são: i) Input x : define a ativação a^1 para camada de entrada; ii) *Feedforward*: para cada $l = 2, 3, \dots, L$ calcula-se $z^l = w^l a^{l-1} + b^l$ e $a^l = \sigma(z^l)$; iii) Erro de saída: δ^L : Cálculo do vetor $\delta^L = \nabla_a C \odot \sigma^1$; iv) Backpropagação de erro: para cada $l = L - 1, L - 2, \dots, 2$ calcula-se $\delta^l = ((w^{l+1})^T \delta^{l+1}) \odot \sigma'(z^l)$; v) Saída: O gradiente da função de custo é dado por: $\frac{\partial C}{\partial w_{jk}^l} = a_j^{l-1}$ e $\frac{\partial C}{\partial b_j^l} = \delta_j^l$.

Como observado, nos algoritmos são calculados os vetores de erro δ^l para trás partindo da camada final. Esse “retrocesso” nas camadas da rede neural é aplicado repetidamente até se obter uma expressão utilizável e aceitável. A informação é transportada para as múltiplas camadas aplicando ajustes atualizando os pesos a cada iteração.

2.16. Métricas

2.16.1. Acurácia

Acurácia é o método que se relaciona com o grau de proximidade de uma extensão estatística e o valor do parâmetro considerado verdadeiro, sendo assim atribuída com a correspondência das observações com os dados de referência (MONICO et al., 2009). A forma em que a acurácia é calculada é o número das predições exatas divididas pelo número do total dos conjuntos dos dados (SANTOS; LINS JÚNIOR, 2018), de acordo com a equação (6):

$$Acurácia = \frac{(VP + VN)}{(VP + VN + FP + FN)} \quad (6)$$

onde VP trata-se dos verdadeiros positivos; VN os verdadeiros negativos; FP representa os falsos positivos; e FN representa os falsos negativos. Para entender as variáveis demonstradas na equação (6), é necessário consultar a matriz de confusão, conforme apresentado na Figura 9.

2.16.2. Matriz de Confusão

Matriz de Confusão é uma forma de ilustrar dados de referência obtidos através de classificação digital de imagem, sendo esses dados percebidos como verdadeiros. Pode ser expressa pela análise de amostras que são obtidas através de treinamentos em conjuntos com dados classificados. É bastante utilizada em trabalhos científicos (PRINA; TRENTIN, 2015). A Figura 9, traz um exemplo de matriz de confusão.

Figura 9. Modelo de Matriz de Confusão.

		Classe verdadeira	
		p	n
Classe Indicada pelo classificador	p	Verdadeiro Positivo (VP)	Falso Positivo (FP)
	n	Falso Negativo (FN)	Verdadeiro Negativo (VN)
Totais		P	N

Fonte: Adaptado de Fawcett (2006).

2.16.3. Precisão

Precisão é utilizada para representar a conexão entre predições positivas verdadeiras com todas predições positivas. Para calcular a precisão é necessário utilizar o número de previsões positivas e dividir pelo número total das previsões positivas (SANTOS; LINS JÚNIOR, 2018), de com a equação (7):

$$Precisão = \frac{(VP)}{(VP + FP)} \quad (7)$$

2.16.4. Recall

Recall é uma medida de completude que determina a porcentagem de ligação entre positivos verdadeiros e negativos falsos. Para calcular essa porcentagem utilizamos a equação (8), onde é realizada a divisão dos verdadeiros positivos pela soma dos verdadeiros positivos com os falsos negativos (HAN; KAMBER; PEI, 2011).

$$Recall = \frac{VP}{(VP + FN)} \quad (8)$$

2.16.5. *F1 Score*

F1 score é uma forma de referenciar verdadeiros positivos e a média presente entre os positivos esperados e os positivos que são existentes (HAN; KAMBER; PEI, 2011). Para realizar o cálculo da métrica *F1 score*, utiliza-se a equação (9).

$$F1Score = \frac{2 \times Precisão \times Recall}{(Precisão + Recall)} \quad (9)$$

2.17. Tecnologias

2.17.1. *Linguagem Python*

Existem diversas bibliotecas de código aberto que permitem a criação de redes neurais profundas com *Python* sem a necessidade de escrever todo o código à mão. De acordo com Vasilev *et al.* (2019), algumas das mais populares são *TensorFlow*, *Keras* e *PyTorch*. Todas possuem certas especificidades para aplicação de diversos problemas. *Python* é uma linguagem de programação direcionada para desenvolvimento de aplicações científicas e comerciais. Ela tem como paradigma a orientação a objetos, porém aceita os paradigmas estruturais e funcionais, por possuir a escrita simples. A linguagem possui estruturas de nível forte (desde simples até níveis complexos) e módulos prontos, além de *frameworks* prontos desenvolvidos por terceiros que podem ser utilizados gratuitamente (BORGES, 2010).

O uso de *Python* facilita o desenvolvimento por ser uma linguagem simples (alto nível), além de ser disponibilizada gratuitamente. A linguagem vem crescendo em várias áreas principalmente na AI e algumas de suas características são a legibilidade na escrita de programas e a não utilização de marcadores.

2.17.2. *Bibliotecas*

TensorFlow é uma biblioteca que possui vários níveis de abstração onde pode-se determinar o que será utilizado de acordo com as necessidades da aplicação, usando a API (Interface de Programação de Aplicativos, do inglês *Application Programming Interface*) *Keras* que facilita o uso da biblioteca. O *TensorFlow*, é a segunda geração do sistema de aprendizado de inteligência artificial da Google, e tem sido preferido por um grande número de pesquisadores em virtude de sua alta flexibilidade, portabilidade, suporte multilíngue e otimização de desempenho (QIN *et al.*, 2018).

3. DESENVOLVIMENTO

O trabalho foi implementado utilizando as bibliotecas *TensorFlow* e *Keras* para o *backend*. O treinamento foi baseado em imagens disponibilizadas pelo INPE (Instituto Nacional de Pesquisa Espaciais). A coleta e seleção dos dados foram feitas de forma manual, de modo que as imagens fossem recortadas em tamanho único com somente os dados a serem analisados (pivô) para a etapa de treinamento. Na etapa de treinamento, também foram submetidas à Rede Neural imagens com dados que não continham Pivô 70 % dos dados coletados, foram usados na etapa do treinamento e 30% na fase de testes. Vale ressaltar que os dados usados na fase de verificação, não foram usados na etapa de treinamento para obtermos resultados mais verdadeiros.

A máquina usada foi um computador com 6 núcleos e 6 *threads* com 9MB de cache e 1.123 GB de armazenamento sendo 240 GB de SSD do tipo M.2 e 1TB de disco rígido com uma GPU AMD *Radeon R7 M460* de 4GB e 8 GB de memória RAM.

A arquitetura da rede consistiu em 5 camadas convolucionais, seguidas por um operador *Relu* para cada camada, três camadas de agrupamento e três camadas totalmente conectadas (*fully connected*). A primeira camada convolucional continha 32 filtros de tamanho 3 x 10 x 10 seguida de um agrupamento do tipo *MaxPooling* com tamanho 2 x 2. A segunda camada foi aumentada para 64 filtros com 16 x 5 x 5. Na terceira camada optou-se por colocar 64 filtros com 32 x 8 x 8 aplicando também *MaxPooling* de 2 x 2. A quarta camada consistia em 128 filtros com 8 x 8 x 40. E a última camada convolucional foi modelada também com 128 filtros 8 x 8 x 40 com *MaxPooling* de 2 x 2 um *Flatten* para transformar uma matriz para um vetor de modo que servisse como entrada para Rede Neural.

As duas primeiras camadas continham 512 neurônios seguidos por um *Dropout* em cada camada da Rede Neural. A última camada (*output layer*) continha apenas 2 neurônios classificadores para as classes de Pivô e não-Pivô, atuando como classificadores binários de saída.

3.1. Obtenção e Pré-Processamento das Imagens

As imagens brutas foram baixadas do portal do INPE do Satélite Landsat em 2019. A região de coleta foi a região de Cristalina-GO, Brasília-DF, Riachinho-MG, Entre RIBEIROS-MG e BRASILÂNDIA de Minas-MG. Após o INPE disponibilizar as imagens para serem baixadas, foi selecionado os Pivôs visualmente e recortado manualmente as imagens

para montagem da base de dados. Da mesma maneira foi aplicado para as imagens com ausência de Pivôs e imagens de testes.

3.2. Treinamento da Rede

O treinamento consistiu primeiramente na normalização dos valores usando uma função de *rescale* para normalizar os valores em 0 e 1. Foi efetuado uma rotação de 10° nas imagens para aumentar o conjunto de dados tendo ângulos diferentes. Nessa etapa foi aplicado o *target_size* para padronizar o tamanho das imagens de testes, treinamento e validação em um padrão de 128 x 128 pixels.

O treinamento foi baseado em 100 épocas que rodou em cada época, 649 imagens. Foi feito a tratativa de 180 imagens que não tinham Pivôs.

3.3. Validação da Rede

No processo de validação da Rede, foi definido que seria usado 70% das imagens na etapa de treinamento. Na segunda etapa, definimos 30% das imagens para fase de testes. A métrica foi baseada em trabalhos anteriores como propõem Carvalho (2015), Menegola *et al.* (2017), e Nielsen (2018) que usaram em média 70% do conjunto de dados para treinamento e 30% do conjunto para testes. As imagens usadas no processo de treinamento, não foram usadas na etapa de validação para melhorar a qualidade e a veracidade dos dados.

3.4. Resultados Obtidos

A implementação desse trabalho se deu por meio do uso da API (Interface de Programação de Aplicação, do inglês *Application Programming Interface*) Keras com *TensorFlow*. Na execução das primeiras épocas rodadas, a Rede mostrou 8,45% de acurácia. Nas épocas posteriores os resultados melhoraram e atingiram 93.75% de acerto devido ao uso das funções da biblioteca Keras e *Tensorflow* que foram: *rotation_range* (para rotacionar a imagens), uso da função *steps_per_epoch* (que faz um tratamento no lote de amostras antes de finalizar uma época como concluída). O valor da função se manteve estável após a 16° época que teve um pequeno caimento na *Loss Function* nas épocas posteriores.

Devido ao seu alto desempenho e pouco tempo de treinamento, foi submetida uma imagem de teste de tamanho 5489 x 5755 contendo Pivôs previamente reconhecidos manualmente. Os resultados alcançados foram considerados satisfatórios. A imagem submetida a Rede continha 137 pivôs identificados manualmente. A Rede conseguiu

identificar corretamente 114 pivôs. Devido ao curto prazo, não foi possível testar um grande conjunto de dados como é o ideal para Redes Neurais Convolucionais e Redes Profundas.

4. CONSIDERAÇÕES FINAIS

No decorrer desse trabalho foi realizado o levantamento teórico sobre Geoprocessamento, abordando Sensoriamento Remoto, a forma como as imagens são obtidas, o que são as bandas espectrais de uma imagem, e como funciona o armazenamento das imagens de satélites no computador. Também foi pesquisado sobre Pivô de irrigação, qual sua função na produção agrícola e o que eles representam para os recursos hídricos da nação e impactos ambientais que eles provocam.

O levantamento Teórico sobre Inteligência Artificial, abordou desde os conceitos iniciais de Inteligência Artificial, Aprendizado de Máquina e Redes Neurais Artificiais, até conceitos mais específicos, como *Deep Learning* e Redes Neurais Convolucionais Profundas.

Foram buscados estudos, artigos, trabalhos afins e cursos de que abordavam o assunto *Deep Learning* para detecção de padrões em imagens que nos norteou para o desenvolvimento deste trabalho. Foi debatido com professores da instituição UniEVANGÉLICA e colegas mestrandos da Universidade Federal do Goiás sobre a modelagem da Rede com sugestões de melhorias ao decorrer deste estudo.

Com estudos e pesquisa necessária, foi possível desenvolver a rede neural proposta. Os resultados obtidos foram satisfatórios do ponto de vista inicial. A acurácia, ao final do treinamento nos mostrou como é grande o poder dessa técnica computacional que tem muito a evoluir nos próximos anos.

Com o desenvolvimento deste Trabalho de Conclusão de Curso, foi possível entender sobre arquiteturas das Redes Neurais, modelagem e aplicabilidade. Observamos os benefícios que a continuidade deste estudo, poderá trazer para a sociedade brasileira com relação ao uso dos recursos hídricos mal gerenciados e dos impactos ao meio ambiente e instigando o meio acadêmico e científico a investir nessa proposta de estudo.

4.1. Sugestão de Trabalhos Futuros

O desenvolvimento tecnológico no cenário agrícola brasileiro, ainda não se faz tão presente quando comparado com os países mais desenvolvidos, que detém maior poder de investimento. Espera-se que com a construção dessa Rede Neural, de arquitetura simples, possa servir de base para estudos futuros e instiguem o meio científico a investir em tal pesquisa tão essencial para sociedade. Melhorias podem ser implementadas com o decorrer

do tempo, sejam no conjunto de treinamento, no processamento gráfico de alta performance, e até no uso de arquiteturas e modelos diferentes para buscar resultados mais interessantes.

REFERÊNCIAS

- AGARAP, Abien Fred. Deep Learning Using Rectified Linear Units (ReLU). **ArXiv.Org**, p. 2–8, 2019. Disponível em: <<https://arxiv.org/abs/1803.08375>>.
- AGUIAR NETO, Décio Gonçalves de. **Transferência de Conhecimento Utilizando Aprendizado Profundo Para Classificação de Imagens Histopatológicas**. 2017. 32 f. Universidade Federal do Ceará, Quixadá, 2017. Disponível em: <http://www.repositorio.ufc.br/bitstream/riufc/29515/1/2017_tcc_dganaguiar.pdf>.
- ARAÚJO, Flávio H. D. et al. Redes Neurais Convolucionais Com Tensorflow: Teoria e Prática. **III Escola Regional de Informática Do Piauí. Livro Anais - Artigos e Minicursos**, v. 1, n. 1, p. 382–406, 2017.
- BORGES, Luiz Eduardo. **Python Para Desenvolvedores**. 2. ed. Rio de Janeiro: Edição do Autor, 2010.
- BRAGA, Alessandra Lopes; OLIVEIRA, Julio Cesar de. Identificação e Quantificação de Áreas Irrigadas Por Pivô Central Utilizando Imagens CCD/CBERS. 2005, Goiânia: [s.n.], 2005. p. 849–856. Disponível em: <<http://marte.sid.inpe.br/col/ltid.inpe.br/sbsr/2004/11.19.16.25/doc/849.pdf>>.
- BUDUMA, Nikhil. **Fundamentals of Deep Learning: Designing Next-Generation Machine Intelligence Algorithms**. Sebastopol, CA: O'Reilly Media, 2017.
- CARVALHO, Micael Cabrera. **Transfer Schemes for Deep Learning in Image Classification**. 2015. 87 f. Universidade Estadual de Campinas, Campinas, 2015. Disponível em: <http://repositorio.unicamp.br/bitstream/REPOSIP/258944/1/Carvalho_MicaelCabrera_M.pdf>.
- CERQUEIRA, Eduardo O. de et al. Redes Neurais e Suas Aplicações Em Clibração Multivariada. **Química Nova**, v. 24, n. 6, p. 864–873, 2001. Disponível em: <<http://repositorio.unicamp.br/jspui/bitstream/REPOSIP/94887/1/2-s2.0-0347117767.pdf>>.
- COELHO, Helder. Turing , 100 Anos Depois Do Seu Nascimento Já Pode Uma Máquina Pensar? **Boletim Da Sociedade Portuguesa de Matemática**, v. 67, p. 9–21, 2012. Disponível em: <<https://revistas.rcaap.pt/boletimspm/article/view/3868/2909>>.
- COPPIN, Ben. **Inteligência Artificial**. Rio de Janeiro: Editora LTC, 2010.
- DATA SCIENCE ACADEMY. **Deep Learning Book**. [S.l.]: Data Science Academy, 2017. Disponível em: <<http://deeplearningbook.com.br/>>.
- DUMOULIN, Vincent; VISIN, Francesco. A Guide to Convolution Arithmetic for Deep Learning. **ArXiv.Org**, p. 1–31, 2018. Disponível em: <<https://arxiv.org/abs/1603.07285>>.
- DUTRA E SILVA, Luís André. Utilização de Deep Learning Em Ações de Controle. **Revista Do TCU**, v. 135, p. 292–296, 2016. Disponível em: <<https://revista.tcu.gov.br/ojs/index.php/RTCU/article/view/1321>>.

ENGESAT. **Imagens de Satélite**. Disponível em: <<http://www.engesat.com.br/imagem-de-satelite/>>.

FARIA, Gedson; ROMERO, Roseli Francelin. Explorando o Potencial de Algoritmos de Aprendizado Com Reforço Em Robôs Móveis. 1999, São José dos Campos: ABRICOM - Associação Brasileira de Inteligência Computacional, 1999. p. 237–242. Disponível em: <http://abricom.org.br/eventos/cbrn_1999/4cbrn_051/>.

FARIAS, Gilles Paiva Medeiros de. **Detecção de Intrusão Em Redes de Computadores: Uma Abordagem Usando Extreme Learning Machines**. 2011. 96 f. Universidade Federal de Pernambuco, Recife, 2011. Disponível em: <https://repositorio.ufpe.br/handle/123456789/2820?locale=pt_BR>.

FAWCETT, Tom. An Introduction to ROC Analysis. **Pattern Recognition Letters**, v. 27, n. 8, p. 861–874, Jun. 2006. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S016786550500303X>>.

FERNANDES, Janderson Gabriel Limeira et al. Inteligência Artificial: Uma Visão Geral. **Revista Eletrônica Engenharia Estudos e Desafios - REED**, v. 3, p. 1–11, 2018. Disponível em: <<http://www.reeed.com.br/index.php/reeed/article/view/25>>.

FERNEDA, Edberto. Redes Neurais e Sua Aplicação Em Sistemas de Recuperação de Informação. **Ciência Da Informação**, v. 35, n. 1, p. 25–30, Apr. 2006. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-19652006000100003&lng=pt&tlng=pt>.

FERREIRA, Alessandro dos Santos. Redes Neurais Convolucionais Profundas Na Detecção de Plantas Daninhas Em Lavoura de Soja. 2017.

FINOCCHIO, Marco Antonio Ferreira. **Noções de Redes Neurais Artificiais**. . [S.l.]: Universidade Tecnológica Federal do Paraná. Disponível em: <[http://paginapessoal.utfpr.edu.br/mafinocchio/labsi-laboratorio-de-seguranca-e-iluminacao/redes-neurais-artificiais/NOCaO DE REDES NEURAI ARTIFICIAIS.pdf/at_download/file](http://paginapessoal.utfpr.edu.br/mafinocchio/labsi-laboratorio-de-seguranca-e-iluminacao/redes-neurais-artificiais/NOCaO%20DE%20REDES%20NEURAI%20ARTIFICIAIS.pdf/at_download/file)>. , 2014

FLORENZANO, Teresa Gallotti. **Imagens de Satélite Para Estudos Ambientais**. [S.l.]: Oficina de Textos, 2002. Disponível em: <<http://books.google.com/books?id=RFLcAAAACAAJ&pgis=1>>. Acesso em: 8 dec. 2013.

_____. **Iniciação Em Sensoriamento Remoto**. 3. ed. São Paulo: Oficina de Textos, 2011. Disponível em: <<http://books.google.com/books?id=18GkH5X81XcC&pgis=1>>. Acesso em: 7 dec. 2013.

GOMES, Dennis dos Santos. Inteligência Artificial: Conceitos e Aplicações. **Olhar Científico**, v. 1, n. 2, p. 234–246, 2010. Disponível em: <<http://www.olharcientifico.kinghost.net/index.php/olhar/article/view/49>>.

GUIMARÃES, Daniel Pereira; LANDAU, Elena Charlotte. **Mapeamento de Áreas Irrigadas Por Pivôs Centrais No Estado de Minas Gerais**. Sete Lagoas: Embrapa Milho e Sorgo, 2011. Disponível em:

<<https://ainfo.cnptia.embrapa.br/digital/bitstream/item/90277/1/bol-40.pdf>>.

HAN, Jiawei; KAMBER, Micheline; PEI, Jian. **Data Mining: Concepts and Techniques**. San Francisco: Morgan Kaufmann Publishers, 2011.

HAYKIN, Simon. **Neural Networks and Learning Machines**. 3. ed. Hamilton: Prentice Hall, 2008.

_____. **Redes Neurais: Princípios e Prática**. 2nd. ed. Porto Alegre: Bookman, 2001.

KOHAVI, Ron; PROVOST, Foster. Glossary of Terms. **Machine Learning**1, v. 30, p. 271–274, 1998. Disponível em: <<http://robotics.stanford.edu/~ronnyk/glossary.html>>.

LANDAU, Elena Charlotte; GUIMARÃES, Daniel Pereira. Levantamento Da Agricultura Irrigada Por Pivôs Centrais No Brasil. 2014, [S.l.]: Embrapa, 2014. p. 1. Disponível em: <<https://ainfo.cnptia.embrapa.br/digital/bitstream/item/128098/1/Levantamento-agricultura-irrigada.pdf>>.

LANDAU, Elena Charlotte; GUIMARÃES, Daniel Pereira; REIS, Ruibran Januário dos. **Mapeamento Das Áreas Irrigadas Por Pivôs Centrais No Estado de Goiás e No Distrito Federal - Brasil**. Sete Lagoas: Embrapa Milho e Sorgo, 2013. Disponível em: <<https://ainfo.cnptia.embrapa.br/digital/bitstream/item/94389/1/bol-77.pdf>>.

LANDAU, Elena Charlotte; GUIMARÃES, Daniel Pereira; SOUSA, Denise Luz de. **Expansão Geográfica Da Agricultura Irrigada Por Pivôs Centrais Na Região Do Matopiba Entre 1985 e 2015**. Sete Lagoas: Embrapa Milho e Sorgo, 2016. Disponível em: <<http://ainfo.cnptia.embrapa.br/digital/bitstream/item/154690/1/bol-136.pdf>>.

LECUN, Yann et al. Backpropagation Applied to Handwritten Zip Code Recognition. **Neural Computation**, v. 1, n. 4, p. 541–551, Dec. 1989. Disponível em: <<http://www.mitpressjournals.org/doi/10.1162/neco.1989.1.4.541>>.

LECUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey. Deep Learning. **Nature**, v. 521, n. 7553, p. 436–444, 27 May 2015. Disponível em: <<http://www.nature.com/articles/nature14539>>.

MAIA, Lucas Bezerra. **Aprendizagem Profunda Aplicada Ao Diagnóstico de Melanoma**. 2019. 86 f. Universidade Federal do Maranhão, São Paulo, 2019. Disponível em: <<http://tedebc.ufma.br:8080/jspui/bitstream/tede/2578/2/LucasMaia.pdf>>.

MANTOVANI, Everardo Chartuni; BERNARDO, Salassier; PALARETTI, Luis Fabiano. **Irrigação: Princípios e Métodos**. 3. ed. Viçosa: UFV, 2009.

MARTINS, Renato Adriano et al. Evolução Da Prática de Irrigação Por Pivô Central No Município de Morrinhos (GO) e a Pressão Sobre Os Recursos Hídricos. **Ambiência**, v. 12, n. 3, p. 881–890, 2016. Disponível em: <<http://www.gnresearch.org/doi/10.5935/ambiencia.2016.Especial.13>>.

MCCULLOCH, Warren S; PITTS, Walter. A Logical Calculus Nervous Activity*. v. 52, n. 1, p. 99–115, 1990.

- MENEGOLA, Afonso et al. Knowledge Transfer for Melanoma Screening with Deep Learning RECOD Lab , IC , University of Campinas (Unicamp), Brazil School of Medicine , Federal University of Minas Gerais (UFMG), Brazil. **In: Simpósio Internacional IEEE de Imagem Biomédica**, 2017.
- MITCHELL, Tom M. **Machine Learning**. New York: McGraw-Hill, 1997.
- MONICO, João Francisco Galera et al. Acurácia e Precisão: Revendo Os Conceitos de Forma Acurada. **Boletim de Ciências Geodésicas**, v. 15, n. 3, p. 469–483, 2009. Disponível em: <<https://revistas.ufpr.br/bcg/article/view/15513/10363>>.
- NEAPOLITAN, Richard E. Neural Networks and Deep Learning. **Artif. Intell.** [S.l.]: Chapman and Hall/CRC, 2018. p. 389–411. Disponível em: <<https://www.taylorfrancis.com/books/9781351384391/chapters/10.1201/b22400-15>>.
- NIELSEN, Michael. Neural Networks and Deep Learning. **Artificial Intelligence**, p. 389–411, 2018.
- PEREIRA, Anderson Soares. Sistemas de Irrigação Pivô Central: Principais Problemas Em Projetos e Assistência Técnica. 2004, Piracicaba: FEALQ, AGROESP, 2004. p. 292–296. Disponível em: <<https://ainfo.cnptia.embrapa.br/digital/bitstream/item/164777/1/2004SP-64-Pereira-Sistemas-15674.pdf>>.
- PEREIRA, Natasha Sophie. **Novos Formatos de Dados e Algoritmos Para Suporte à Imagens Multi-Dimensionais**. 2014. 118 f. Centro Universitário de Anápolis - UniEVANGÉLICA, Anápolis, 2014.
- PÉREZ CASTAÑO, Arnaldo. **Practical Artificial Intelligence: Machine Learning, Bots, and Agent Solutions Using C#**. New York, NY: Apress, 2018.
- PONTI, Moacir Antonelli; COSTA, Gabriel B. Paranhos da. Como Funciona o Deep Learning. **Tópicos Em Gerenciamento Dados e Informações Minicursos Do SBBB 2017**. [S.l.]: Simpósio Brasileiro de Banco de Dados, 2017. p. 63–93. Disponível em: <http://conteudo.icmc.usp.br/pessoas/moacir/papers/Ponti_Costa_Como-funciona-o-Deep-Learning_2017.pdf>.
- PRINA, Bruno Zucuni; TRENTIN, Romario. GMC: Geração de Matriz de Confusão a Partir de Uma Classificação Digital de Imagem Do ArcGIS®. 2015, João Pessoa: INPE, 2015. p. 131–139. Disponível em: <<http://www.dsr.inpe.br/sbsr2015/files/p0031.pdf>>.
- QIN, Jinbo et al. Simulating and Predicting of Hydrological Time Series Based on TensorFlow Deep Learning. **Polish Journal of Environmental Studies**, v. 28, n. 2, p. 795–802, 2018. Disponível em: <<http://www.pjoes.com/doi/10.15244/pjoes/81557>>.
- REZENDE, Solange Oliveira. **Sistemas Inteligentes: Fundamentos e Aplicaciones**. Barueri: Manole, 2003.
- RICHARDS, John A.; JIA, Xiuping. **Remote Sensing Digital Image Analysis: An Introduction**. 4th. ed. Germany: Springer-Verlag, 2006.
- RODRIGUES E SILVA, Saulo; SCHIMIDT, Fernando. Redução de Variáveis de Entrada

de Redes Neurais Artificiais a Partir de Dados de Análise de Componentes Principais Na Modelagem de Oxigênio Dissolvido. **Química Nova**, v. 39, n. 3, p. 273–278, 2016. Disponível em: <<http://www.gnresearch.org/doi/10.5935/0100-4042.20160024>>.

ROJAS, Raúl. **Neural Networks: A Systematic Introduction**. Berlin: Springer, 1996. Disponível em: <<https://page.mi.fu-berlin.de/rojas/neural/neuron.pdf>>.

RUSSELL, Stuart J.; NORVIG, Peter. **Artificial Intelligence: A Modern Approach**. 2. ed. [S.l.]: Prentice Hall, 2003.

SANTOS, Alan et al. Uma Abordagem de Classificação de Imagens Dermatoscópicas Utilizando Aprendizado Profundo Com Redes Neurais Convolucionais. 2017, Porto Alegre: Sociedade Brasileira de Computação, 2017. p. 10. Disponível em: <<https://sol.sbc.org.br/index.php/sbcas/article/view/3717>>.

SANTOS, Miqueas Galdino dos; LINS JÚNIOR, Paulo Ribeiro. Avaliação de Técnicas Estatísticas Para Detecção de Anomalias Aplicadas à Internet Das Coisas. **Revista de Tecnologia Da Informação e Comunicação**, v. 8, n. 1, p. 13–18, 2018. Disponível em: <<http://rtic.com.br/index.php/rtic/article/view/95>>.

SETTI, Arnaldo Augusto et al. **Introdução Ao Gerenciamento de Recursos Hídricos**. 2. ed. Brasília: Nacional de Energia Elétrica, Superintendência de Estudos e Informações Hidrológicas, 2000. Disponível em: <http://www.aneel.gov.br/documents/656835/14876406/2001_IntroducaoGerenciamentoRecursosHidricos2ed/75352f44-fa8d-ae7-8fc3-aca3ffbff972>.

SILVA, Euzebio Medrado da; AZEVEDO, Juscelino Antônio de. **Dimensionamento Da Lateral de Irrigação Do Pivô Central**. Planaltina: Embrapa-CPAC, 1998. Disponível em: <<https://www.infoteca.cnptia.embrapa.br/bitstream/doc/554798/1/doc71.pdf>>.

SOMPOLINSKY, Haim. **Introduction: The Perceptron**. [S.l.]: MIT. Disponível em: <http://web.mit.edu/course/other/i2course/www/vision_and_learning/perceptron_notes.pdf>. , 2013

SOUZA, Flavio Clesio Silva de; SASSI, Renato Jose. Aplicação de Redes Neurais Artificiais Do Tipo Multilayer Perceptron Na Criação de Modelos Para Classificação de Um Portfólio Do Tipo Non-Performing Loans. 2013, Salvador: [s.n.], 2013. p. 1–18. Disponível em: <http://www.abepro.org.br/biblioteca/enegep2013_TN_STO_179_023_22203.pdf>.

SOUZA, Mauricio Bonato Alves de. **Análise Técnica de Sistemas de Irrigação Por Pivô Central Utilizados Na Cafeicultura Irrigada Do Norte Do Espírito Santo e Extremo Sul Da Bahia**. 2001. 123 f. Universidade Federal de Viçosa, Viçosa, 2001. Disponível em: <<https://www.locus.ufv.br/handle/123456789/11449>>.

SPOLTI, Amanda Costa. Classificação de Vias Através de Imagens Aéreas Usando Deep Learning. 2018.

TESTEZLAF, Roberto. **Irrigação: Métodos, Sistemas e Aplicações**. Campinas: Unicamp/FEAGRI, 2017. Disponível em: <<https://econtents.bc.unicamp.br/omp/index.php/ebooks/catalog/book/978-85-99678-10->

7>.

VALLEY IRRIGATION. **Pivô Central (8000)**. Disponível em: <<http://www.valleyirrigation.com.br/equipamento/pivô-central/pivô-central-8000>>. Acesso em: 12 may 2019.

VASILEV, Ivan et al. **Python Deep Learning: Exploring Deep Learning Techniques and Neural Network Architectures with PyTorch, Keras and TensorFlow**. 2. ed. [S.l.]: Packt Publishing, 2019.

VON ZUBEN, Fernando José. **Redes Neurais**. . Campinas: UNICAMP. Disponível em: <http://www.dca.fee.unicamp.br/~lbocato/ia353_1s2017.html>. , 2017

YOSINSKI, Jason et al. How Transferable Are Features in Deep Neural Networks? **Advances in Neural Information Processing Systems**, v. 27, p. 3320–3328, 2014. Disponível em: <<https://arxiv.org/abs/1411.1792>>.

ZOU, Lian et al. A Technical Review of Convolutional Neural Network-Based Mammographic Breast Cancer Diagnosis. **Computational and Mathematical Methods in Medicine**, v. 2019, p. 1–16, 25 Mar. 2019. Disponível em: <<https://www.hindawi.com/journals/cmmm/2019/6509357/>>.