

Estudo Comparativo a Partir da Aplicação de Técnicas de Aprendizagem Profunda Baseadas em Dados Pluviométricos Coletados por Estação Meteorológica Automática

Comparative Study Based on the Application of Deep Learning Techniques Based on Rainfall Data Collected by an Automatic Weather Station

Roney Nogueira de Sousa
Instituto Federal do Ceará, Brasil
nogueiraroney453@gmail.com

Rhyan Ximenes de Brito
Instituto Federal do Ceará Brasil
rxbrito@gmail.com

Janaide Nogueira de Sousa Ximenes
Universidade Estadual do Ceará, Brasil
nogueirajanaide@gmail.com

ABSTRACT

Rains play an important role in the social context, as they bring the possibility of planning for the cultivation and harvesting of various food crops. Thus, the study aimed to predict rainfall through the application of Convolutional Neural Networks. For the methodology, we used a database collected by an automatic weather station and the implementation of LeNet, VGGNet, ResNet, AlexNet and GoogLeNet architectures, in addition to the normalization techniques *k-fold*, SMOTE and *z-score*. The results showed that the GoogLeNet architecture obtained the best average of hits with 92.45%, while for the specificity and the false positive rate, the AlexNet architecture obtained the best results with 96.14% and 3.867% respectively.

Keywords

Deep Learning; Meteorology; Rainfall

RESUMO

As chuvas desempenham um importante papel no contexto social, por trazerem a possibilidade de planejamento para o cultivo e colheita de diversas culturas alimentares. Assim, o estudo teve como finalidade a previsão de precipitações pluviométricas através da aplicação de Redes Neurais Convolucionais. Para a metodologia utilizou-se de uma base de dados coletada por uma estação meteorológica automática e da implementação das arquiteturas LeNet, VGGNet, ResNet, AlexNet e GoogLeNet, além das técnicas

de normalização *k-fold*, SMOTE e *z-score*. Os resultados demonstraram que a arquitetura GoogLeNet obteve a melhor média de acertos com 92,45%, enquanto que para a especificidade e a taxa de falsos positivos, a arquitetura AlexNet obteve os melhores resultados com 96,14% e 3,867% respectivamente.

Palavras-Chave

Aprendizagem Profunda; Meteorologia; Pluviométricos

1. INTRODUÇÃO

As precipitações pluviométricas conhecidas como chuva são as formas mais baratas e ambientalmente adequadas de uso da água na agricultura, colaborando para a manutenção do equilíbrio dos recursos hídricos existentes em qualquer região [17]. Assim observa-se que o desenvolvimento agrário de uma região está associado aos níveis de chuva, uma vez que a escassez é um fator desfavorável para o processo produtivo.

Por outro lado a utilização de algoritmos de aprendizagem profunda (AP) possuem como uma de suas vantagens a capacidade de aprendizagem em grandes quantidades de dados, o que os tornam uma importante ferramenta para a análise de grandes volumes de dados como os pluviométricos, principalmente partindo do conceito de que para as AP foram propostas novas ideias, originando assim as redes neurais profundas, como as Redes Neurais Convolucionais (RNC). O presente trabalho teve como objetivo principal realizar a previsão de chuvas com base em dados pluviométrica extraídos de uma estação meteorológica automática localizada em uma cidade do interior do estado do Ceará. Para o estudo foi utilizada uma base de dados, disponível através do portal INMET (Instituto Nacional de Meteorologia) ¹.

A metodologia utilizada baseou-se no estudo bibliográfico e na implementação das seguintes arquiteturas de redes neurais convolucionais: *ResNet*, *LeNet*, *VGGNet*, *AlexNet*

¹<https://portal.inmet.gov.br/>

Permission to make digital or hard copies of all or part of this work for personal or classroom use is granted without fee provided that copies are not made or distributed for profit or commercial advantage and that copies bear this notice and the full citation on the first page. To copy otherwise, or republish, to post on servers or to redistribute to lists, requires prior specific permission and/or a fee.

e *GoogLeNet* apoiadas em técnicas como validação cruzada (*k-fold*), balanceamento dos dados e na técnica SMOTE, em seguida realizou-se um comparativo entre os resultados baseados em procedimentos quantitativos realizados com base no treinamento e teste.

A motivação para este trabalho está relacionada a importância da aplicação de técnicas de Inteligência Artificial (IA) em situações que possam auxiliar profissionais da área da agricultura, oferecendo assim suporte de forma direta ou indireta na tomada de decisões no campo, pois tais informações afetam ações relacionadas a irrigação, plantio, transporte, produção de proteína animal, etc.

Este trabalho está dividido nas seguintes seções: a Seção 2 descreve alguns trabalhos relacionados, Seção 3 traz a fundamentação teórica necessária para a melhor compreensão sobre o trabalho, como mineração de dados, redes neurais artificiais e redes neurais convolucionais com ênfase para as arquiteturas escolhidas para a implementação nesse estudo, na Seção 4 é descrito os materiais e métodos utilizados. A Seção 5 apresenta os resultados e discussões, por fim a Seção 6 expõe as conclusões e trabalhos futuros.

2. TRABALHOS RELACIONADOS

Esta seção apresenta uma revisão bibliográfica de forma reflexiva sobre diferentes abordagens sobre o uso de técnicas de IA aplicadas como ferramentas de auxílio na previsão climática.

[27] utilizou a base de dados constituída da série histórica dos valores de precipitação total mensal nos meses do verão em Paty de Alferes obtida junto ao Instituto Nacional de Meteorologia, no período de 1993 a 2013. O modelo computacional utilizado para a predição de precipitação pluviométrica foi baseado em redes neurais *Perceptron* de Múltiplas Camadas (MLP). O erro obtido pela rede MLP foi equivalente a 3,2% quando analisado o período de 2010 a 2013.

[13] apresenta uma abordagem computacional para a predição de um passo à frente em séries de dados meteorológicos pertencentes às regiões de Paty do Alferes e Paracambi. Para tanto, foram utilizados dois modelos de Redes Neurais Artificiais: *Perceptrons* de Múltiplas Camadas (MLP) e Função de Base Radial (RBF). Apresentando resultados favoráveis entre 91% e 96% de acerto para todos os casos.

[15] buscou prever a precipitação de chuva do dia seguinte utilizando dados meteorológicos dos últimos 7 dias. Para cumprir tal objetivo foi avaliado diversos algoritmos de Redes Neurais Artificiais assim como Lógica *Fuzzy* para série temporal aplicando-os para predição de chuva. Dos vários algoritmos avaliados o *Levenberg-Marquardt* e *Bayesian Regularization* apresentaram menores desvios médios entre os valores observados e preditos.

[34] desenvolveram um trabalho com a utilização de classificadores como *Random Forest* (RF), Regressão Linear (RL) e *Support Vector Machine* (SVM) em uma série de dados de vazão e chuvas diárias obtidos a partir de uma estação pluviométrica automática. Tomando como base os resultados adquiridos, percebeu-se que os melhores resultados foram entre 49,80% e 53,20% para o R^2 de acordo com a abordagem aplicada.

[20] utilizou-se de redes neurais artificiais para previsão do volume de precipitações mensal na cidade de Manaus. Foram considerados dados de 1950 a 2015 e índices climáticos de temperatura da superfície do mar que influenciam

a precipitação na região de interesse. Foram propostas, treinadas e testadas diferentes redes neurais para o problema em questão e, para cada mês do ano, foi selecionada a rede com melhor acurácia. Os resultados obtidos mostraram a adequação dos modelos propostos, com taxa de acerto superior a 92%.

[37] construiu um modelo híbrido combinando redes neurais e algoritmos genéticos, objetivando o reconhecimento dos padrões dos dados assim como a previsão dos índices baseados na precipitação pluviométrica. Utilizaram-se de correlações de Spearman com análise interanual e análise decadal. Assim percebeu-se que a análise decadal apresentou bons resultados para faixa espectral decadal com coeficientes de correlação acima de 0,3. Dessa forma pode-se constatar que o trabalho mostrou que a maior porção da variabilidade pluviométrica ocorrida na estação seca, decorre tanto de fenômenos meteorológicos de pequena escala quanto das características físicas das bacias, enquanto a menor porção pode ser explicada pelos fenômenos globais com ênfase para as condições do oceano Atlântico.

[3] realizou uma classificação baseada em estimativas de precipitação com redes neurais compostas por 3 classes distintas tendo como finalidade a avaliação da capacidade do método de detectar chuvas intensas. Assim utilizou-se de redes neurais de aproximação para o processamento do conjunto de variáveis de entrada e estimar a variável de saída (precipitação horária). Sendo realizada uma bateria de testes sobre as condições iniciais da rede neural que por fim mostrou resultados promissores para a detecção de eventos de chuvas torrenciais, com ênfase para a redução do número de falsos de positivos quando comparado a estudo realizados anteriormente.

[19] simularam o fenômeno de conversão de chuvas em vazões do Rio Guamá localizado no estado do Pará. Os modelos utilizados pelos autores foram baseados em redes neurais como a *Multilayer Perceptron* e *Nonlinear Autoregressive with Exogenous Inputs*, com o regramento de hiperparâmetros como a função de ativação Tangente Hiperbólica nos neurônios da camada oculta, com os algoritmos de treinamento supervisionado *Levenberg-Marquardt*. Ao serem comparadas as redes neurais, os autores perceberam que o modelo *Nonlinear Autoregressive with Exogenous Inputs* apresentou melhor desempenho frente ao modelo *Multilayer Perceptron*. Assim os resultados mostraram a possibilidade da simulação de vazões de pequenas e médias bacias hidrográficas da Amazônia principalmente com ausência ou limitação de dados.

Nesse contexto evidencia-se que independentemente da natureza das pesquisas a serem realizadas, os investigadores ao recorrerem às ferramentas digitais procuraram assegurar que os dados por si recolhidos tenham sido analisados de forma criteriosa e sistemática, gerindo mais eficazmente o tempo despendido e aumentando a confiabilidade dos resultados obtidos [2].

3. FUNDAMENTAÇÃO TEÓRICA

Esta seção aborda um estudo mais aprofundado sobre os principais conceitos necessários para um melhor entendimento da abordagem proposta nesse trabalho, com destaque para as redes neurais convolucionais *ResNet*, *LeNet*, *VGGNet*, *AlexNet* e *GoogLeNet* com suas particularidades.

3.1 Mineração de Dados

A partir do surgimento dos sistemas computacionais, uma das principais preocupações das organizações é o armazenamento dos dados. Atualmente essa preocupação ficou ainda mais evidente, pois a quantidade de dados armazenados é cada vez maior.

Para [29], com o volume de dados armazenados crescendo a cada segundo, responder uma questão tornou-se crucial: O que fazer com esses dados? Essa atividade não é trivial, visto que as técnicas tradicionais de processamento de dados não são mais adequadas para tratar a grande maioria dos repositórios.

Dentro dessa perspectiva tem-se a Mineração de Dados, do inglês *Data Mining* que foi proposta, no final da década de 80, com o intuito de sanar as dificuldades em relação a exploração destes dados. De acordo com [11] a mineração de dados abrange o entendimento de banco de dados, estatística, matemática, engenharia, sistemas de informação, visualização de dados e inteligência artificial.

[44], [11], [36] e [9] listam algumas das áreas na quais a Mineração de Dados é aplicada de forma satisfatória:

- (i) **Retenção de clientes:** reconhecimento de perfis para compra de determinados produtos;
- (ii) **Bancos:** identificação de padrões financeiros para auxiliar no gerenciamento de relacionamento com o cliente;
- (iii) **Eleitoral:** detecção de um perfil para possíveis votantes;
- (iv) **Medicina:** indicação de diagnósticos mais precisos;
- (v) **Tomada de Decisão:** identificação dos dados mais importantes, a fim de fornecer indicadores de probabilidade;
- (vi) **Segurança:** na detecção de atividades terroristas e criminais.

Assim para [21] a mineração de dados é uma etapa do processo que corresponde a aplicação de algoritmos com capacidade de extrair conhecimentos a partir de dados. Esse termo foi criado com base no processo de mineração correspondente a extração de minerais valiosos, uma vez que busca em bases de dados através de algoritmos conhecimentos úteis no contexto da aplicação [23]. Dentre as várias técnicas utilizadas para mineração de dados podem ser citadas as redes neurais artificiais, redes neurais convolucionais, classificadores estatísticos entre tantas outras.

Para [10] a mineração de dados é capaz de realizar diversas tarefas, dentre elas:

- (i) **Descrição:** descreve padrões e tendências com base na interpretação dos dados. É muito utilizada para verificar a influência de certas variáveis no resultado obtido;
- (ii) **Classificação:** visa identificar a qual classe um determinado registro pertence;
- (iii) **Estimação:** visa estimar o valor de uma determinada variável;
- (iv) **Predição:** é muito parecida com a tarefa de estimação e classificação, entretanto visa prever o valor futuro de um determinado atributo;
- (v) **Agrupamento:** consiste em identificar e aproximar registros similares, criando clusters de dados similares;
- (vi) **Associação:** visa identificar quais atributos estão relacionados.

3.2 Redes Neurais Artificiais (RNAs)

As RNAs são um paradigma de processamento de informação, ou seja, um modelo computacional inspirado no sistema neural biológico [45]. São sistemas massivamente paralelos e distribuídos, formados por unidades de processamento simples, que calculam determinadas funções, normalmente não lineares, distribuídas em camadas, sendo interligadas por conexões que se associam a pesos, que por sua vez armazenam o conhecimento representado na rede, servindo para ponderar entradas recebidas por unidades constituintes [24].

Dessa forma podem ser compreendidas como uma técnica que permite imitar as estruturas e os mecanismos de raciocínio utilizados pelos operadores no cumprimento de suas atividades, estando inspirada em conceitos desenvolvidos na modelagem cognitiva, utilizando os formalismos de representação de estruturas de domínio da IA, que é um vasto campo que contém diversos componentes importantes, como as RNAs [22]. É importante destacar que [18] afirma que a pesquisa exploratória utilizando RNAs em outras áreas do conhecimento tem crescido nas últimas décadas, devido a evolução da capacidade de processamento, interpretação e análise de grandes volumes de dados.

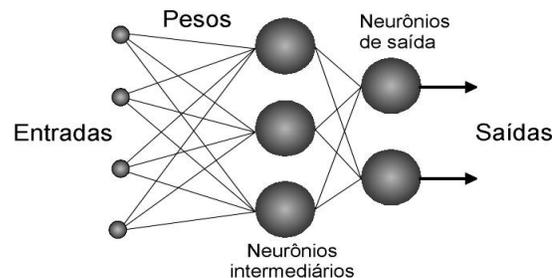


Figure 1: Exemplo de Topologia de Rede Neural Artificial

A Figura 1 apresenta um exemplo de arquitetura de rede neural artificial, onde podem ser observadas a camada de entrada, camada oculta e camada de saída, com seus respectivos neurônios.

Vale salientar que de acordo com [22] uma das primeiras e mais simples formas de rede neural artificial foram as *perceptrons*, com seus neurônios dispostos em várias camadas, que podem ser classificadas em camadas de entrada, onde os padrões são apresentados para a rede; camadas ocultas conhecidas também como camadas escondidas ou intermediárias, onde é feita a maior parte do processamento; e a camada de saída, onde o resultado do processamento é apresentado.

Dentro dessa perspectiva [8] as redes neurais podem ser direcionadas a três grupos de atividades específicas: modelagem, aplicações e implementações. Salienta-se ainda que o processo de modelagem de redes neurais abrange três níveis, neurônios, arquiteturas e algoritmos de aprendizagem. O neurônio tem como finalidade estabelecer a unidade computacional básica da rede, já a arquitetura definirá a estrutura de conexões entre os neurônios. Por outro lado o algoritmo de aprendizagem descreve um método para alterar o estado individual dos neurônios e as conexões entre eles, objetivando atingir um comportamento global para a rede.

Para uma melhor compreensão faz-se necessária a compreensão do funcionamento de um neurônio biológico e de

um neurônio artificial descritos nas subseções seguintes.

3.2.1 Neurônio Biológico

[22] afirma que durante a evolução dos seres vivos, a multicelularidade levou a especialização de funções aos diversos tecidos orgânicos. Paralelamente surgiram sistemas para coordenar as atividades dos diversos tecidos e órgãos desses seres, onde o sistema nervoso é um dos responsáveis por esta coordenação.

Já para [25], ainda não é compreendido de forma completa como é dado o funcionamento dos processos envolvidos no sistema nervoso, sendo portanto necessário várias pesquisas para se concluir como o modelo biológico neuronal funciona efetivamente. Entretanto um modelo simplificado, baseado no mecanismo fundamental, pode ser adotado. Dessa maneira [22] afirma que os neurônios são a unidade básica da neuroanatomia e por apresentarem a propriedade de responder a alterações do meio, através de modificações da diferença de potencial elétrico que existe entre as superfícies interna e externa da membrana celular, reagindo prontamente a estes estímulos e as mudanças de potencial propagando-se a outros neurônios.

Com relação aos componentes básicos de um neurônio, [7] ressalta inicialmente que o soma é a parte central do neurônio conforme visto na Figura 2, onde estão presentes as organelas e o núcleo, funcionando também como um receptor e integrador de estímulos. Os dendritos são numerosos prolongamentos que recebem estímulos nervosos e os transmitem para o corpo da célula. Dessa forma aumentam consideravelmente a superfície celular, tornando exequível receber e integrar impulsos trazidos por numerosos terminais axônicos. Já o axônio é responsável pela condução dos impulsos elétricos que partem do corpo celular, até outro local mais distante, como outras células nervosas, musculares ou até mesmo glandulares. Na Figura 2 observa-se uma representação esquemática de um neurônio biológico com seus componentes básicos.

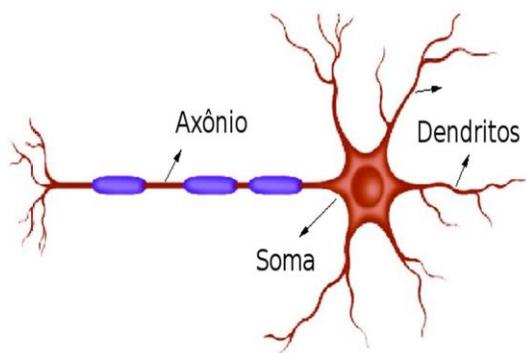


Figure 2: Componentes Básicos de um Neurônio (Adaptado de [7])

3.2.2 Neurônio Artificial

Para [22] o neurônio artificial pode ser entendido como uma estrutura lógico-matemática que simula a forma e o comportamento das funções de um neurônio biológico. Assim pode-se perceber que de forma associativa o dendrito são a entrada, o soma o processamento e o axônio a saída, foi justamente essa ideia que fez com que [32] propusessem

um dos modelos de neurônios mais fundamentais até hoje estudado. Na Figura 3 pode ser observado uma representação esquemática do neurônio artificial desenvolvido no trabalho de [32].

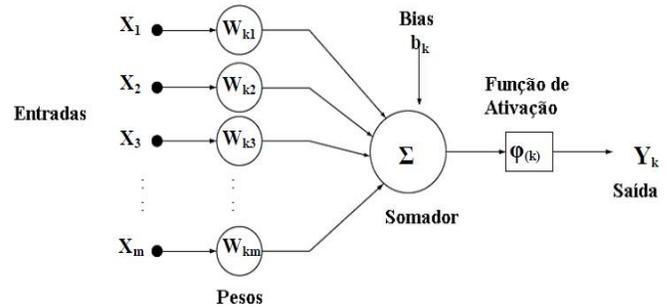


Figure 3: Neurônio Artificial de McCulloch-Pitts

Foi a partir desse modelo que outros modelos foram derivados permitindo outras saídas e não apenas 0 ou 1, conforme proposta inicial [32]. Salienta-se ainda que o neurônio artificial proposto é um modelo simplificado de um neurônio biológico. Igualmente [8] enfatiza que para um dado instante de tempo o neurônio está disparando ou inativo. Dessa maneira recebe e produz um valor booleano, com conexões excitatórias e inibitórias representadas através de um peso com sinal que reforça ou dificulta a geração de um impulso.

Matematicamente o modelo apresentado na Figura 3 pode ser representado através da fórmula apresentada abaixo [22]. Nessa fórmula, pode-se perceber que x_j são os sinais de entrada, w_{kj} são os pesos sinápticos, y_k , são os sinais de saída $\varphi(\cdot)$ é a função de ativação. Além disso, para uma maior fidelidade ao modelo biológico e maior flexibilidade computacional, além da excitação vinda das entradas da rede, cada neurônio também é excitado por uma polarização constante chamada *bias*, constante de valor 1, transmitida ao neurônio através da sinapse.

$$u_k = \sum_{j=1}^n w_{kj} \cdot x_j$$

$$y_k = \varphi(u_k)$$

[22] ressalta que o modelo de neurônio proposto por [32] ainda se apresenta constante para quase todas as redes neurais, porém há uma variedade na função de ativação. Complementarmente [8] destaca que esta função de ativação limita a amplitude do sinal de saída, onde normalmente percebe-se que a faixa de saída está em um intervalo fechado $[0, 1]$ ou alternativamente em $[-1, 1]$, podendo este intervalo de saída estar entre $(-\infty, +\infty)$, visto que a função de ativação pode ser determinada por outros modelos que permitem saídas quaisquer, não necessariamente zeros ou um. Na Figura 4 podem ser observadas algumas funções de ativação mais comumente utilizadas.

3.3 Redes Neurais Convolucionais (RNC)

Para [18] as redes neurais convolucionais são um tipo de rede neural artificial especializada para o processamento de dados de entrada que possuem um formato de matriz, usualmente utilizadas para o processamento de informações visuais. O que caracteriza esse tipo de rede é o fato da mesma

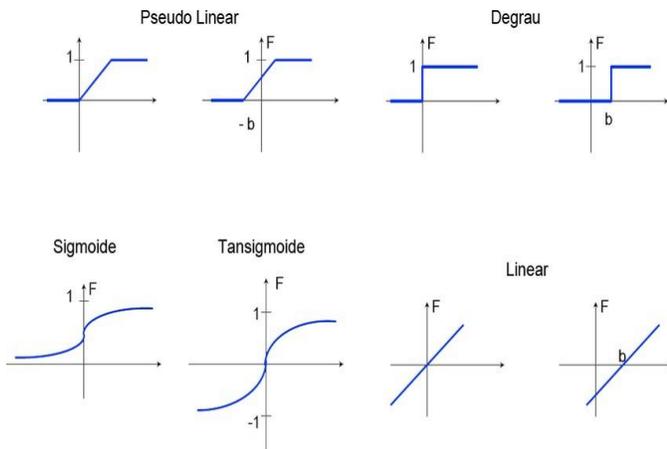


Figure 4: Funções de Ativação

ser composta basicamente de camadas convolutivas, que processam as entradas considerando campos receptivos locais. Em outras palavras, as redes neurais convolucionais são uma espécie de extrator de características automático que antecede uma rede neural artificial do tipo *Multilayer Feedforward* para classificação do resultado em classes distintas.

Segundo [35] são compostas por diversas camadas que utilizam a operação de convolução para realizar tal extração de características, onde são realizadas a partir de uma janela de dados deslizantes, comumente chamadas de filtro convolutivo, que percorre toda a entrada da rede e opera de forma similar a sobreposição dos campos receptivos. O modelo pode conter diversos filtros, dos quais os valores são ajustados durante o processo de treinamento para a obtenção de características distintas a partir da entrada. Ao final, estas características extraídas tornam-se entradas de um algoritmo de aprendizado aplicado de acordo com o tipo de problema que pode ser classificação ou regressão.

As redes neurais convolucionais são arquiteturas multi-estágios possuindo a capacidade de serem treinadas, com campos receptivos altamente correlacionados na localidade do estímulo à imagem capturada, utilizam este conceito forçando um padrão de conectividade entre as camadas de neurônios artificiais [26].

Vale salientar que as redes neurais convolucionais são complexas do ponto de vista operacional e uma técnica bastante utilizada para reduzir o custo computacional é o procedimento de *pooling* durante as camadas convolutivas de uma RNC que consiste em uma forma de reduzir a dimensionalidade espacial dos mapas de características gerados pela rede [18].

A Figura 5 abaixo apresenta um exemplo de arquitetura de uma rede neural convolucional.

3.3.1 Camada de Entrada

A camada de entrada é responsável por receber os padrões que serão apresentados para a rede neural convolucional processar, seja na fase de treinamento ou na fase de classificação, e assim seguir para a camada seguinte (camada convolucional) [39].

3.3.2 Camada Convolutacional

Na camada convolutacional percebe-se que cada neurônio é

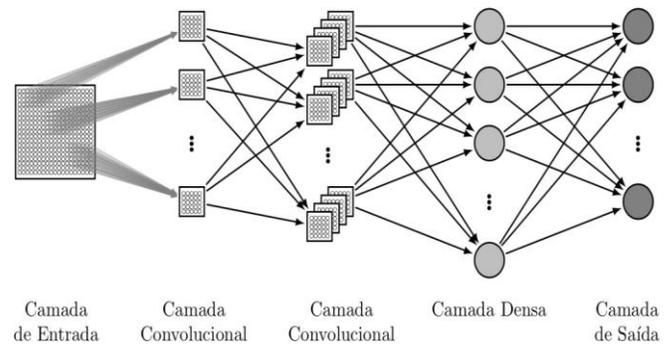


Figure 5: Exemplo de Topologia da Rede Neural Convolutacional

utilizado como um filtro aplicado a uma dada entrada. Esse filtro é constituído por uma matriz de pesos. Assim, cada neurônio irá processar a entrada e produzir uma transformação dessa entrada por meio de uma combinação linear utilizando dados vizinhos [39]. Dessa forma o objetivo dessa camada é a realização do processo de extração de características através da aplicação de um *kernel* [41].

3.3.3 Camada Densa

De acordo com [18], nesta camada cada neurônio possui um peso associado a cada elemento do vetor de entrada. A transição entre uma camada convolutacional e a camada densa exige que o mapa de característica gerado pelas camadas convolutivas seja transformado em um vetor, o qual é utilizado como peso de entrada para a camada densa.

3.3.4 Camada de Saída

A camada de saída é responsável por receber as informações das camadas intermediárias e construir o padrão que constituirá a resposta final, com base em todo o processamento gerado pela rede neural convolucional [16]. Abaixo tem-se as equações (1) e (2) que possuem relação direta com a camada de saída de uma rede convolucional [5].

$$f(x) = h^{(L+1)}(x) = o(a^{(L+1)}(x)) \quad (1)$$

$$o(q^{L+1}) = \frac{e^{a_i^{(L+1)}}}{\sum_{j=1}^C e^{a_j^{(L+1)}}} \quad (2)$$

De acordo com [5] a Equação 1. representa a função de ativação usada para unidades da camada de saída quando realizada uma classificação, onde tem-se $o(.)$ função denominada *softmax*, que interpreta valores da camada de saída como probabilidade posteriores. Já a Equação 2. é o resultado produzido pela função *softmax* para i -ésima unidade da camada de saída.

Ressalta-se ainda que para [39], arquiteturas mais recentes de redes neurais convolucionais tem utilizado a função de ativação *ReLU* para as camadas ocultas e a função *softmax* para a camada de saída.

3.3.5 Configuração de Parâmetros em RNC

Para a implementação de uma rede neural convolucional, deve-se levar em conta a necessidade de definir hiperparâmetros que serão ajustados, entre eles podem ser citados: número

de camadas convolucionais C (para cada camada, o número de filtros, seu tamanho e o tamanho do passo dado durante a convolução), número de camadas de *pooling* P (sendo nesse caso necessário escolher também o tamanho da janela e do passo que definirão o fator de subamostragem), o número de camadas totalmente conectadas F (e o número de neurônios contidos em cada uma dessas camadas) [39]. Dessa maneira sabe-se que o treinamento de uma RNC busca pela configuração de uma série de hiperparâmetros que levem a validação dos resultados [38].

3.3.6 Arquitetura Neural Convolutiva ResNet

A rede *ResNet* é uma estrutura robusta que é capaz de alcançar um dos melhores resultados na área de redes convolucionais. Conforme [31] a publicação dessa arquitetura de rede permitiu que fossem construídas e otimizadas várias redes muito mais profundas, com ela são alcançados desempenhos superiores as arquiteturas disponíveis até então.

Essa arquitetura trabalha na proposta em que as camadas continuem a receber os valores resultantes das funções de ativação *Rectified Linear Unit*, da camada anterior, mas também recebam os valores de entrada x dessas funções [42]. [6] complementa ao afirmar que em algumas arquiteturas convencionais de redes neurais convolucionais o erro calculado é retro propagado e passado diretamente de uma camada para a próxima de forma linear, fazendo assim com que o gradiente seja recalculado em toda a rede. Porém em redes residuais como a *ResNet* são construídos certos tipos de atalhos que ignoram certas camadas da rede e passam o valor do gradiente mais para o início da rede sem que ele seja suavizado em inúmeras camadas. A Figura 6 mostra um exemplo da arquitetura de rede *ResNet* com suas particularidades.

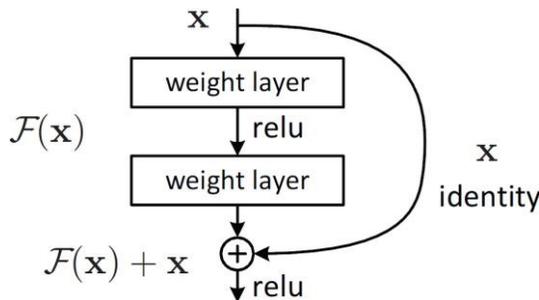


Figure 6: Arquitetura da Rede Neural Convolutiva ResNet

Segundo [14] esta técnica foi a vencedora do concurso ImageNet ILSVRC 2015. A *ResNet* avaliou a base de teste do ImageNet que tinha 1.000 classes e alcançou incríveis 3.6% em taxa de erro no top5. A avaliação top5 consiste na verificação das 5 classes com maiores probabilidades após uma classificação, e caso esta imagem de fato pertença ao grupo destas 5 classes é considerado uma classificação correta. A *ResNet* proposta para o concurso tinha 152 camadas caracterizando uma rede muito profunda.

3.3.7 Arquitetura Neural Convolutiva LeNet

A *LeNet* foi uma das primeiras redes neurais convolucionais que ajudaram a impulsionar o campo da AP. No trabalho pioneiro de [30], aplicaram uma rede convolutiva, então chamada de *LeNet*, no reconhecimento de mais de

60.000 caracteres manuscritos e compararam seus resultados com outras técnicas as quais apresentaram desempenho similar à *LeNet*, porém em relação a demanda de memória computacional, a rede neural convolutiva demandou muito menos memória que as demais técnicas utilizadas. Essa rede neural convolutiva foi denominada *LeNet5*. Naquela época, a arquitetura *LeNet* era usada principalmente para tarefas de reconhecimento de caracteres, como leitura de Código de Endereçamento Postal (CEP), dígitos, entre outros. [4].

A arquitetura *LeNet* é uma rede neural convolutiva composta por 7 camadas, possuindo parâmetros ou pesos treináveis, proposta por [30], inspirada no *Neocognitron*. Segundo [4] a arquitetura *LeNet* possui uma estrutura simples e pequena. Quando se trata de memória ocupada, ela pode até mesmo rodar puramente em uma única *Central Processing Unit* (CPU), tornando-a uma ótima arquitetura para aplicações envolvendo RNCs e sistemas embarcados.

[33] enfatiza que por um longo período a *LeNet* foi considerada o estado da arte das redes neurais convolucionais, considerado o primeiro passo para uma real aplicação do método de aprendizagem profunda. A Figura 7 exibe um exemplo da arquitetura *LeNet*.

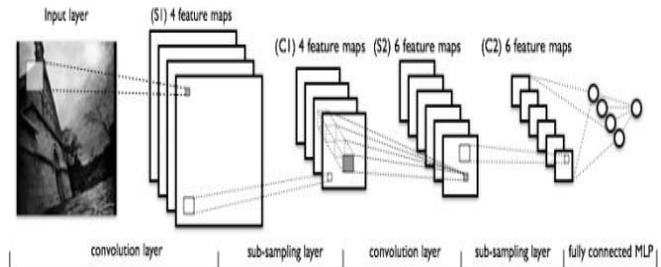


Figure 7: Arquitetura da Rede Neural Convolutiva LeNet.

3.3.8 Arquitetura Neural Convolutiva VGGNet

Um outro exemplo das arquiteturas utilizadas na AP é a *VGGNet*, essa arquitetura foi proposta por [12], projetada para aumentar a profundidade das redes. Por requerer uma maior memória e tempo de execução que a *AlexNet* é considerada a mais difícil de ser treinada [43].

De acordo com [14] a *VGGNet* foi a vice-campeã do desafio ILSVRC 2014, tendo alcançado 6.8% na taxa de erro top5. Tendo como sua principal contribuição a avaliação exaustiva de seis redes neurais convolucionais, que consistiu no aumento de profundidade enfatizando a utilização de filtros de convolução com tamanho muito pequeno, promovendo o aumento da profundidade da rede que passou de 16 para 19 camadas. A abordagem mostrou um aumento de eficiência significativo comparado as técnicas anteriores. Além disso a *VGGNet* é composta principalmente por camadas de convolução chamadas de *maxpooling*, completamente conectadas e *softmax*. A Figura 8 mostra um exemplo da arquitetura de rede *VGGNet* com suas características.

3.3.9 Arquitetura Neural Convolutiva AlexNet

AlexNet é uma rede neural convolutiva originalmente criada por [28], possuiu como inspiração a arquitetura de rede *LeNet*. Destacando-se por ser grande e muito profunda,

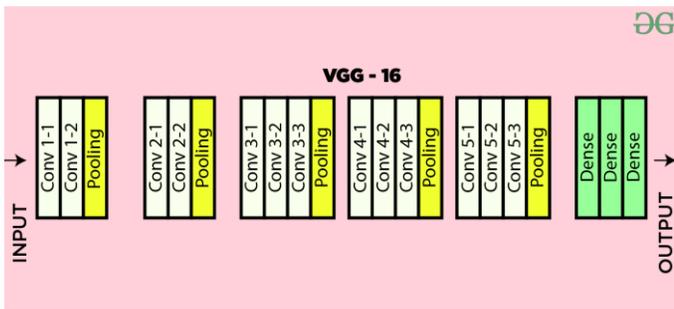


Figure 8: Arquitetura da Rede Neural Convolucional VGGNet.

a AlexNet foi a primeira RNC a empilhar camadas de convolução ao invés da tradicional conexão entre uma camada de convolução e a camada de *pooling* [14].

Para [28], a arquitetura AlexNet possui oito camadas, com cinco convolucionais, onde acontece o maior número de operações, e três camadas totalmente conectadas, onde percebe-se cada entrada conectada a cada saída. A última é conhecida como camada de saída, que apresenta uma distribuição entre as classes de objetos definidos no início da rede, com a camada de saída possuindo uma distribuição de 1.000 diferentes rótulos de objetos. A Figura 9 mostra um exemplo da arquitetura de rede AlexNet.

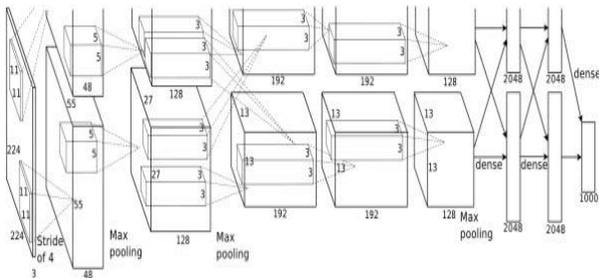


Figure 9: Arquitetura da Rede Neural Convolucional AlexNet

[14] afirma que a AlexNet usa uma normalização bastante eficiente entre as camadas C1 e C3 denominada *local response normalization*. Essa normalização causa um efeito que contribui para a inibição dos neurônios em ativar mais fortemente no mesmo local. Desta forma, outros mapas de características também adquirem computação e aprendizagem referente a sub-região da imagem, comportamento também observado nos neurônios biológicos.

3.3.10 Arquitetura Neural Convolucional GoogLeNet

A *GoogLeNet* é uma arquitetura de rede neural convolucional desenvolvida por um time de desenvolvedores da Google que usa módulos de iniciação, ou seja, diferentes tipos de tamanho de *kernel*, como 1×1 , 3×3 , 5×5 , e uma camada *maxpooling* no mesmo módulo por concatenação [46]. A Figura 10 mostra um exemplo dessa arquitetura de rede convolucional.

A terminação "*LeNet*" serve como um tributo a rede *LeNet* criada por [30], considerada a pioneira da área de redes con-

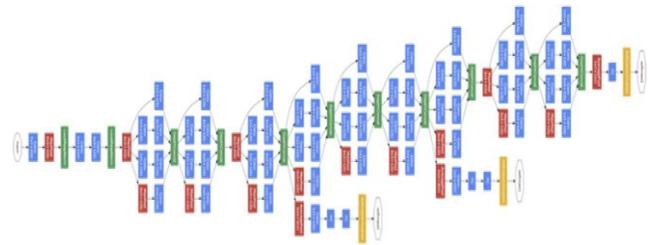


Figure 10: Arquitetura da Rede Neural Convolucional GoogLeNet

volucionais. Vale ressaltar que essa arquitetura entre suas várias características, emprega a utilização da técnica de *pooling* médio global ao final da rede, assim como o chamado módulo *inception* [40].

Apesar da *GoogLeNet* ser muito profunda, ela usa menos parâmetros que muitas outras arquiteturas de redes neurais convolucionais. Por outro lado, a *GoogLeNet* é muito poderosa devido ao fato das camadas iniciais incluírem todos os tamanhos de *kernel* e a camada *maxpooling* em um único módulo inicial [1].

4. MATERIAIS E MÉTODOS

Para o emprego dos algoritmos utilizados nesse trabalho fez o uso da linguagem *Python* em sua versão 3.7 e uma base em dados pluviométrica extraída de uma estação meteorológica automática localizada em uma cidade do interior do estado do Ceará obtidos através do link: <https://portal.inmet.gov.br/>. Os dados utilizados foram coletados levando em consideração as informações obtidas durante o intervalo de 15/03/2018 a 11/05/2021. Salienta-se ainda que eles passaram pelo processo de pré-processamento onde algumas amostras com atributos ausentes foram descartadas, assim como atributos que não estavam relacionados a classificação, além do descarte de informações redundantes.

A base de dados utilizada após o pré-processamento, possui 23.879 amostras e 16 atributos como por exemplo, temperatura máxima, temperatura mínima, umidade máxima, umidade mínima, pressão atmosférica, velocidade dos ventos, entre outros. Ressalta-se ainda que foram adicionadas a base de dados 22.436 amostras sintéticas através da técnica *SMOTE*. Quanto a variável desfecho ela foi trabalhada com relação a ocorrência de chuvas na região. Assim as classes foram codificadas com "0" para ausência de chuva e "1" para presença de chuva. Para a classificação baseada nas arquiteturas utilizadas, salienta-se que foram testados vários hiperparâmetros de forma a ajustá-los através da estratégia *Randomized Search* a atingirem os melhores resultados.

Para a normalização dos dados foi utilizada a técnica (*z-score*), já o balanceamento foi realizado através do método *SMOTE* garantindo assim a proporcionalidade entre as amostras utilizadas. Vale salientar que a geração dos dados sintéticos foi relacionada a classe minoritária a partir de vizinhos. Além disso foi utilizado o método de validação cruzada *k-fold*, com o $k=10$ folds, outras configurações foram testadas porém ele proporcionou os melhores resultados.

5. RESULTADOS E DISCUSSÕES

Os resultados obtidos foram analisados tendo como base os percentuais da taxa média da acurácia adquiridos durante os treinamentos e testes realizados. Para o trabalho também foram analisados os resultados relacionados a sensibilidade e especificidade.

Como observado na Tabela 1, o melhor caso da arquitetura *LeNet* atingiu uma acurácia de 92,49% de acertos e 7,51% de erros e o pior caso 89,68% de acertos e 10,32% de erros. Para a taxa média de acertos percebe-se 91,03% para 8,97 % de erros. Ao ser analisadas a especificidade, a *LeNet* atingiu 95,23% e 4,77% de falso negativo.

Table 1: Resultados com a Arquitetura LeNet

Folds	Taxa de Acerto	Taxa de Erro	Situação
1	91,06%	9,94%	
2	92,49%	7,51%	Melhor Caso
3	90,55%	9,45%	
4	91,60%	8,40%	
5	90,45%	9,55%	
6	89,68%	10,32%	Pior Caso
7	90,06%	9,94%	
8	92,26%	7,74%	
9	91,70%	8,30%	
10	90,53%	9,47%	
- -	91,03%	8,97%	Caso Médio

Nota-se na Tabela 2 que o melhor caso da arquitetura *ResNet* atingiu uma acurácia de 90,34% de acertos e 9,66% de erros e para o pior caso 87,56% de acertos e 12,44% de erros. A taxa média de acertos foi de 89,17% e 10,83% de erros. Para a especificidade a rede *ResNet* atingiu 90,25% e 9,75% de falso negativo.

Table 2: Resultados com a Arquitetura ResNet

Folds	Taxa de Acerto	Taxa de Erro	Situação
1	87,56%	12,44%	Pior Caso
2	90,12%	9,88%	
3	90,25%	9,75%	
4	89,49%	10,51%	
5	88,36%	11,64%	
6	90,16%	9,84%	
7	88,45%	11,55%	
8	87,69%	12,31%	
9	89,26%	10,74%	
10	90,34%	9,66%	Melhor Caso
- -	89,17%	10,83%	Caso Médio

Já à Tabela 3, observa-se que o melhor caso da arquitetura *VGGNet* atingiu uma acurácia de 92,75% de acertos e 7,25% de erros e para o pior caso 90,36% de acertos e 9,64% de erros. A taxa média de acertos foi de 91,53% e 8,47% de erros. Para a especificidade a rede *VGGNet* atingiu 92,49% e 7,51% de falso negativo.

A Tabela 4 mostra os resultados adquiridos com a arquitetura *AlexNet* onde atingiu 94,12% de acerto para o melhor caso com uma taxa de erro de 7,88% de erro. Já para o pior caso percebeu-se uma taxa de 90,08% de acerto com uma taxa de erro de 9,92% de erro. A taxa média de acertos ficou em torno de 91,91% com 8,09% de erro. Para a especificidade foi adquirido 96,14% e 3,86% para falso positivo.

Table 3: Resultados com a Arquitetura VGGNet

Folds	Taxa de Acerto	Taxa de Erro	Situação
1	92,65%	7,35%	
2	91,69%	8,31%	
3	92,75%	7,25%	Melhor Caso
4	90,56%	9,44%	
5	91,83%	8,17%	
6	90,36%	9,64%	Pior Caso
7	92,16%	7,84%	
8	91,31%	8,69%	
9	91,62%	8,38%	
10	90,36%	9,64%	Pior Caso
- -	91,53%	8,47%	Caso Médio

Table 4: Resultados com a Arquitetura AlexNet

Folds	Taxa de Acerto	Taxa de Erro	Situação
1	92,12 %	7,88%	
2	91,15%	8,85%	
3	90,12%	9,88%	
4	90,08%	9,92%	Pior Caso
5	94,12%	5,88%	Melhor Caso
6	92,25%	7,75%	
7	92,39%	7,61%	
8	91,29%	8,71%	
9	93,65%	6,35%	
10	92,02%	7,98%	
- -	91,91%	8,09%	Caso Médio

Abaixo tem-se a Tabela 5 com os resultados obtidos a partir da arquitetura *GoogLeNet*, onde pôde-se comprovar que o melhor caso atingiu uma taxa de acerto de 94,65% e 5,35% de erro. O pior caso atingiu 90,45% de acerto e 9,47% para o erro. A taxa média de acerto ficou em torno de 92,45% e 7,55% para o erro. Quando analisada a especificidade observou a taxa de 95,19% e 4,81% para o falso positivo.

Table 5: Resultados com a Arquitetura GoogLeNet

Folds	Taxa de Acerto	Taxa de Erro	Situação
1	94,65%	5,35%	Melhor Caso
2	93,12%	6,88%	
3	93,15%	6,85%	
4	94,06%	5,94%	
5	91,12%	8,88%	
6	91,56%	8,44%	
7	90,98%	9,02%	
8	92,68%	7,32%	
9	92,56%	7,44%	
10	90,53%	9,47%	Pior Caso
- -	92,45%	7,55%	Caso Médio

A Tabela 6 apresenta uma comparação entre as taxas médias de acertos obtidas pelas arquiteturas utilizadas (*LeNet*, *ResNet*, *VGGNet*, *AlexNet* e *GoogLeNet*), nela pode-se perceber claramente que a arquitetura *GoogLeNet* obteve o melhor resultado com 92,45% de acertos.

A Tabela 7 traz um quadro comparativo entre as arquiteturas utilizadas nesse trabalho dando ênfase para as taxas de especificidade e falso positivo.

Table 6: Quadro Comparativo Entre as Arquiteturas

Arquitetura AP	Taxa Média de Acertos	Situação
ResNet	89,17%	Pior Resultado
LeNet	91,03%	
VGGNet	91,53%	
AlexNet	91,91%	
GoogLeNet	92,45%	Melhor Resultado

Table 7: Comparativo: Especificidade e Falso Positivo

Arquitetura AP	Especificidade	Falso Positivo
ResNet	90,25%	9,75%
LeNet	95,23%	4,77%
VGGNet	92,49%	7,51%
AlexNet	96,14%	3,86%
GoogLeNet	95,19%	4,81%

Na tabela acima percebe-se claramente que a arquitetura *AlexNet* adquiriu a melhor taxa para a especificidade e a menor taxa para o falso positivo. Podendo ser ressaltado que essa arquitetura está entre as que melhor destacaram-se entre as demais utilizadas no estudo em questão.

6. CONCLUSÕES E TRABALHOS FUTUROS

O artigo relatou a utilização de redes neurais convolucionais para a previsão de precipitações pluviométricas em uma cidade do interior do Ceará com base em um banco de dados coletado através de uma estação meteorológica automática levando em consideração as informações obtidas durante o intervalo de 15/03/2018 a 11/05/2021.

No estudo realizado percebe-se que a arquitetura *AlexNet* e *GoogLeNet* obtiveram as melhores médias de acertos para as acurácias com 91,91% e 92,45% respectivamente, porém quando analisadas as taxas de especificidade e falso negativo pôde-se perceber que a arquitetura *AlexNet* atingiu o melhor resultado com 96,14% de especificidade e 3,86% para o falso positivo enquanto a arquitetura *VGGNet* obteve 92,49% para a especificidade e 7,51% para o falso positivo. Já a arquitetura *ResNet* obteve a pior média de acertos com 89,17%, assim como os piores resultados para a especificidade e taxa de falso negativos.

Como trabalhos futuros sugere-se a utilização de outras arquiteturas de redes neurais e/ou classificadores estatísticos com a finalidade de comparar os resultados de modo a descobrir quais arquiteturas melhor se adequam ao problema proposto.

7. REFERENCES

- [1] A. G. Araújo, H. Mukhandi, M. S. Couceiro, J. Valença, and E. Júlio. Medição da extensão em laminados de cfrp pré-esforçados no reforço de elementos de betão a partir de imagens: machine learning versus deep learning. *Revista Portuguesa de Engenharia de Estruturas*, 2021.
- [2] J. B. Baugh, A. S. Hallcom, and M. E. Harris. Computer assisted qualitative data analysis software: a practical perspective for applied research. *Revista Digital Del Instituto Internacional de Costos*, (6):69–81, 2010.
- [3] P. BENEVIDES, J. CATALÃO, G. NICO, and P. M.

- MIRANDA. Aplicação de técnicas de redes neuronais para previsão de chuvas torrenciais combinando dados de vapor de água gnss e medições meteorológicas.
- [4] A. L. Bertoni and D. V. d. S. Feder. Rede neural convolucional aplicada à visão computacional para detecção de incêndio. B.S. thesis, Universidade Tecnológica Federal do Paraná, 2018.
 - [5] E. Bezerra. Introdução à aprendizagem profunda. *Artigo-31º Simpósio Brasileiro de Banco de Dados-SBBD2016-Salvador*, 2016.
 - [6] S. A. B. Block et al. Inspeção e classificação de picos em peças estampadas de metal utilizando rede neural convolucional. Master's thesis, Universidade Tecnológica Federal do Paraná, 2018.
 - [7] R. R. Borges, K. C. Iarosz, A. M. Batista, I. L. Caldas, F. S. Borges, and E. L. Lameu. Sincronização de disparos em redes neuronais com plasticidade sináptica. *Revista Brasileira de Ensino de Física*, 37:2310–1, 2015.
 - [8] J. R. F. Brega et al. A utilização de redes neurais artificiais em um sistema de gerência de pavimentos. *Repositório Institucional EESCA*, 2018.
 - [9] P. Cabena, P. Hadjinian, R. Stadler, J. Verhees, and A. Zanasi. *Discovering data mining: from concept to implementation*. Prentice-Hall, Inc., 1998.
 - [10] C. O. Camilo and J. C. d. Silva. Mineração de dados: Conceitos, tarefas, métodos e ferramentas. *Universidade Federal de Goiás (UFG)*, 1(1):1–29, 2009.
 - [11] L. N. d. Castro and D. G. Ferrari. Introdução à mineração de dados: conceitos básicos, algoritmos e aplicações. *São Paulo: Saraiva*, 2016.
 - [12] K. Chatfield, K. Simonyan, A. Vedaldi, and A. Zisserman. Return of the devil in the details: Delving deep into convolutional nets. *arXiv preprint arXiv:1405.3531*, 2014.
 - [13] E. R. Coutinho, R. M. Silva, and A. R. S. Delgado. Utilização de técnicas de inteligência computacional na previsão de dados meteorológicos. *Revista Brasileira de Meteorologia*, 31:24–36, 2016.
 - [14] A. A. d. Cruz et al. Uma abordagem para reconhecimento de emoção por expressão facial baseada em redes neurais de convolução. 2019.
 - [15] M. da Costa Ferreira, J. V. Rocha, D. Sannomia, and T. B. Ferreira. Método simplificado para previsão de chuva aplicado no agronegócio. In *Congresso Transformação Digital 2019*, 2019.
 - [16] K. B. DA CUNHA. Reconhecimento e detecção de logotipos a partir de redes neurais convolucionais profundas.
 - [17] D. Dantas, T. M. O. Luz, M. J. H. de Souza, G. P. Barbosa, and E. G. S. Cunha. Uso de redes neurais artificiais na previsão da precipitação de períodos chuvosos. *Revista Espinhaço | UFVJM*, pages 11–18, 2016.
 - [18] D. S. de Freitas, S. da Silva Camargo, H. B. Comin, R. Domingues, E. B. Gaspar, and F. F. Cardoso. Reconhecimento da ceratoconjuntivite infecciosa bovina utilizando imagens termográficas e redes neurais convolucionais. *Revista Brasileira de Computação Aplicada*, 11(3):133–145, 2019.
 - [19] L. M. de Mendonça, I. de Souza Gomide, J. V.

- de Sousa, and C. J. C. Blanco. Modelagem chuva-vazão via redes neurais artificiais para simulação de vazões de uma bacia hidrográfica da amazônia. *Revista de Gestao de Água da América Latina*, 18(2021), 2021.
- [20] R. dos Santos Sousa, L. Silva, E. B. Guedes, and M. B. L. de Oliveira. Redes neurais artificiais aplicadas à previsão antecipada de precipitações na região central de manaus. *IV Escola Regional de Informática Norte I*, pages 1–9, 2017.
- [21] D. G. FERRARI and L. N. D. C. SILVA. *Introdução a mineração de dados*. Saraiva Educação SA, 2017.
- [22] M. I. V. Furtado. Redes neurais artificiais: uma abordagem para sala de aula. *Ponta Grossa, PR. Atena Editora*, 2019.
- [23] R. Goldschmidt and E. Passos. *Data mining*. Gulf Professional Publishing, 2005.
- [24] S. Haykin. *Redes neurais: princípios e prática*. Bookman Editora, 2007.
- [25] S. Haykin and R. Lippmann. Neural networks, a comprehensive foundation. *International journal of neural systems*, 5(4):363–364, 1994.
- [26] G. D. Juraszek et al. Reconhecimento de produtos por imagem utilizando palavras visuais e redes neurais convolucionais. 2014.
- [27] K. H. Kawase, E. R. Coutinho, and R. M. da Silva. Aplicação de modelo computacional de redes neurais na previsão de dados pluviométricos no município de paty alferes-rj. *Proceeding Series of the Brazilian Society of Computational and Applied Mathematics*, 3(1), 2015.
- [28] A. Krizhevsky, I. Sutskever, and G. E. Hinton. Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25:1097–1105, 2012.
- [29] D. T. Larose and C. D. Larose. *Discovering knowledge in data: an introduction to data mining*, volume 1. John Wiley & Sons, 2005.
- [30] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11):2278–2324, 1998.
- [31] R. A. P. Martins et al. Aplicação de redes convolucionais profundas para detecção de massas em mamografias. 2019.
- [32] W. S. McCulloch and W. Pitts. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4):115–133, 1943.
- [33] D. d. S. Motta. Otimização na classificação automática de mosquitos adultos: uma investigação com redes neurais convolucionais (cnn). 2019.
- [34] A. Oliveira, A. Oliveira, and R. Brito. Séries temporais e técnicas de regressão: Uma análise comparativa a partir de dados de precipitações pluviométricas coletados por estação meteorológica automática. In *Anais do XIV Encontro Unificado de Computação do Piauí e XI Simpósio de Sistemas de Informação*, pages 97–104, Porto Alegre, RS, Brasil, 2021. SBC.
- [35] R. Oliveira, E. Alves, C. Malqui, L. Martø, and N. S. Pi. Redes neurais convolucionais aplicadas à previsão robótica. In *Anais do 13 Congresso Brasileiro de Inteligência Computacional*, pages 1–11. Curitiba, PR: ABRICOM, 2017.
- [36] D. L. Olson and D. Delen. *Advanced data mining techniques*. Springer Science & Business Media, 2008.
- [37] T. A. d. S. PEREIRA. Análise e previsão de chuvas na estação seca do leste do nordeste do brasil: aplicação nas bacias dos rios mundaú e paraíba do meio (al/pe). 2017.
- [38] D. Pina, L. Kunstmann, D. de Oliveira, P. Valdúriez, and M. Mattoso. Uma abordagem para coleta e análise de dados de configurações em redes neurais profundas. In *SBB D 2020-35ª Simpósio Brasileiro de Banco de Dados*, pages 1–6, 2020.
- [39] M. A. Ponti and G. B. P. Da Costa. Como funciona o deep learning. *arXiv preprint arXiv:1806.07908*, 2018.
- [40] R. R. d. Santos. Detecção de ataques de apresentação facial utilizando redes neurais convolucionais e informações de contexto. Master’s thesis, Escola de Engenharia, Programa de Pós-graduação em Engenharia Elétrica: Universidade Federal do Rio Grande do Sul, Porto Alegre, 2019.
- [41] I. R. Silva, R. G. de Souza, G. Silva, C. S. de Oliveira, L. H. Cavalcanti, R. S. Bezerra, A. d. A. Roberta, and W. P. dos Santos. Utilização de redes convolucionais para classificação e diagnóstico da doença de alzheimer. *II Simpósio de Inovação em Engenharia Biomédica*, pages 73–76, 2018.
- [42] V. Souza, L. Silva, A. Santos, and L. Araújo. Análise comparativa de redes neurais convolucionais no reconhecimento de cenas. *Anais do Computer on the Beach*, 11(1):419–426, 2020.
- [43] L. H. Vogado, R. M. Veras, A. R. Andrade, L. G. Santos, K. R. Aires, and V. P. Machado. Um sistema de diagnóstico de leucemia utilizando cnn’s pré-treinadas e um comitê de classificadores. In *Anais do XVII Workshop de Informática Médica*. SBC, 2017.
- [44] I. H. Witten, E. Frank, M. A. Hall, C. Pal, and M. DATA. Practical machine learning tools and techniques. In *DATA MINING*, volume 2, page 4, 2005.
- [45] R. Ximenes de Brito, C. A. Rolim Fernandes, and M. A. Baima Amora. Análise de desempenho com redes neurais artificiais, arquiteturas mlp e rbf para um problema de classificação de crianças com autismo. *iSys - Brazilian Journal of Information Systems*, 13(1):60–76, dez. 2019.
- [46] Z. Zhong, L. Jin, and Z. Xie. High performance offline handwritten chinese character recognition using googlenet and directional feature maps. In *2015 13th International Conference on Document Analysis and Recognition (ICDAR)*, pages 846–850. IEEE, 2015.