

Detecção de Autismo em Imagens Faciais usando Redes Neurais Convolucionais

Graciano Barbosa Lima Junior¹, José Gilvan Rodrigues Maia¹

¹Instituto Universidade Virtual – Universidade Federal do Ceará (UFC)
Campus do Pici, S/N – Fortaleza – CE – Brasil

gracianobarbosalimajunior@gmail.com, gilvanmaia@virtual.ufc.br

Resumo. *O Transtorno do Espectro Autista (TEA) é uma doença que, durante a infância, se manifesta por meio de desordens cognitivas e linguísticas. TEA é um desafio significativo para a sociedade e a para ciência por conta de diversos aspectos como prevalência na população, bem como por apresentar características sutis, complexas e duradouras para a vida dos pacientes. Note-se que isso é ainda mais importante no caso das crianças. Isso posto, é um desafio detectar corretamente evidências que possam levar a um diagnóstico precoce e confiável, permitindo que as famílias e os serviços de saúde possam conduzir terapias mais efetivas, inclusivas e com maior potencial de êxito. A literatura relata diversos esforços multidisciplinares para detectar a síndrome, sendo o diagnóstico realizado de modo clínico. O presente trabalho tem como objetivo de contribuir para a detecção de autismo em crianças ao investigar a potencialidade prática das Redes Neurais Convolucionais (CNNs) aplicadas às imagens das faces dos pacientes. Os resultados dos experimentos indicam que é possível obter uma acurácia acima de 82% combinando uma CNN com técnicas de detecção e alinhamento de faces.*

1. Introdução

O Transtorno do Espectro Autista (TEA, porém doravante citado apenas como autismo para fins de simplificar a escrita deste trabalho) é uma síndrome caracterizada do desenvolvimento caracterizada por déficits de comunicação, de socialização e por comportamentos repetitivos [Di Martino et al. 2014]. Há algumas poucas décadas, o autismo era considerado um transtorno raro, i.e., quando se acreditava que atingia 1 a cada 2.500 pessoas [Trevvarthen 1998]. Contudo, os avanços nas pesquisas clínicas e subsequente popularização de meios inovadores de diagnóstico trouxe à tona uma realidade mais preocupante. Em junho de 2021 a Organização Mundial da Saúde (OMS) revelou estatísticas epidemiológicas indicando que o TEA afeta uma em cada 160 crianças em todo o mundo; no entanto, a incidência de TEA em muitos países de baixa e média renda permanece desconhecido. Esse cenário pode ser ainda mais complexo, pois o distúrbio pode atingir 1 a cada 50 crianças, quando se consideram os diversos graus do TEA ¹.

É importante salientar que existem outros tipos de transtornos com características semelhantes como deficiência emocional e alexitimia, transtorno do déficit de atenção com hiperatividade e *borderline* [Trevvarthen 1998]. As semelhanças entre o autismo

¹<https://www.saude.mg.gov.br/component/gmg/story/6884-autismo-afeta-cerca-de-1-da-populacao#:text=A%20Organiza%C3%A7%C3%A3o%20Mundial%20de%20Sa%C3%BAde,possuam%20algum%20grau%20do%20transtorno> acesso em 12 de dezembro de 2022.

quando comparado a esses e outros transtornos produzem um erro no diagnóstico [Akter et al. 2021]. Assim, é importante fomentar o desenvolvimento de novas ferramentas de triagem, com o intuito não apenas de torná-las mais confiáveis, como também mais simples de usar e mais econômicas — fator crucial à luz do crescente número de casos de TEA e dos custos associados ao diagnóstico e ao tratamento.

Hipotetiza-se portanto que a detecção automatizada por meio de um instrumento computacional baseado em aprendizagem de máquina possa contribuir sob as perspectivas de confiabilidade, economicidade e agilidade, desde que o sistema possa usar como entrada uma imagem da face de uma criança paciente [Akter et al. 2021].

1.1. Objetivos

O objetivo principal deste trabalho é analisar a viabilidade no uso de tecnologias de Aprendizado de Máquina para realizar a detecção de evidências do autismo a partir de imagens faciais de crianças.

Para atingir tal propósito geral, os seguintes objetivos específicos foram elencados:

1. Identificar bases de imagens que possam ser usadas para o desenvolvimento desta pesquisa;
2. Desenvolver um protótipo para detecção de autismo em imagens faciais; e
3. Avaliar e discutir os resultados obtidos.

1.2. Considerações sobre Aspectos Éticos

A partir deste ponto, o presente trabalho tratará a questão como um problema de aprendizagem de máquina e pautado no processamento de faces, abstraindo-se de maus usos e aplicações nocivas que essa tecnologia pode representar. É importante destacar que o objetivo do trabalho não é lidar diretamente com humanos, muito menos obter, coletar e armazenar imagens de pacientes, assumindo que seja possível reusar coleções de imagens disponíveis publicamente e já difundidas na literatura. Ressalte-se que qualquer aplicação real para além deste trabalho demandará a devida aprovação e avaliação criteriosa, rigorosa e transparente junto à área de saúde.

Por fim, nenhuma imagem dos indivíduos nos conjuntos e dados será veiculada na apresentação deste trabalho para preservar questões de privacidade.

2. Referencial Teórico

Inicialmente, a presente seção introduz termos e conceitos sobre Inteligência Artificial (IA), Aprendizagem de Máquina e Redes Neurais Convolucionais (CNNs). Após isso, são apresentados os principais trabalhos relacionados encontrados na literatura que abordam detecção de autismo via processamento de faces.

2.1. Aprendizagem de Máquina e Redes Neurais Convolucionais

O termo Inteligência Artificial identifica uma área multidisciplinar, oriunda da ciência da computação, que possui como objetivo dotar computadores de capacidades “inteligentes” para executar tarefas complexas, notadamente as que requeiram uma inteligência humana [Russell 2010]. Isso geralmente é implementado por meio de algoritmos embasados em modelos estatísticos e matemáticos que conseguem realizar controle, tomadas de decisão, classificar padrões e modelar funções.

Tem-se na Aprendizagem Profunda [LeCun et al. 2015] o mais recente avanço da tecnologia para a área de IA, que historicamente sofre com períodos de “depressão” e “euforia”: a introdução das redes neurais profundas dotou os algoritmos de processo de aprendizado que embute a extração de representações e características (artificiais) a partir de brutos. Assim, a modelagem por especialistas deu lugar à ao aprendizado de representações objetivamente úteis para realizar a tarefa à qual a rede neural está sendo treinada para realizar — introduzindo a *convolução* como operador básico desse processo.

Todavia, as redes neurais profundas geralmente carecem de uma grande quantidade de amostras de entrada para que produzam resultados aceitáveis — limitação conhecida como *data hunger*. As CNNs se consolidaram como uma tecnologia de base para muitas pesquisas e produtos, uma vez que já supera a capacidade humana em diversas tarefas. Desse modo, as mesmas já foram usadas na literatura para lidar com a detecção de problemas neurológicos [Alchalabi et al. 2018, Loo and Makeig 2012, Zhang et al. 2021].

2.2. Trabalhos Relacionados

Até onde foi possível pesquisar, [Mujeeb Rahman and Subashini 2022] foram os pioneiros a publicar um artigo sobre como usar a imagem da face como biomarcador para fins de detecção do autismo em crianças. Esses autores recorreram a um *dataset* público no portal Kaggle² para sua pesquisa, muito embora a sua disponibilidade fosse descontinuada. Cinco modelos de arquiteturas diferentes foram ajustados para lidar com o problema de classificação: MobileNet, Xception, EfficientNetB0, EfficientNetB1 e EfficientNetB2. Esses modelos não foram apenas ajustados mas também usaram estimativas de medidas antropométricas extraídas usando uma CNN. Os autores relataram que EfficientB0 é capaz de classificar 59,33% dos casos de autismo e 58,67% de desenvolvimento normal com um nível de 95% de confiança.

Mais recentemente, [Hosseini et al. 2022] desenvolveram um estudo semelhante, utilizando o mesmo conjunto de dados, sendo 90% para treinamento e 10% para avaliação de uma CNN do tipo MobileNet. Esses autores reportam uma acurácia de 94,64% e que segundo a metodologia dos experimentos realizados em [Mujeeb Rahman and Subashini 2022], não pode ser comparada diretamente em termos de resultados. Contudo, os resultados de [Hosseini et al. 2022] superam os 87% de acurácia reportados por [Khosla et al. 2021] usando a mesma família de redes neurais MobileNet.

3. Materiais e Métodos

3.1. *Autistic Children Facial Image Data Set*

Trata-se de um conjunto de imagens disponibilizado inicialmente via Kaggle³ e que posteriormente foi publicizado pelo seu autor original, autodenominado “Garry”, via Google Drive⁴. Até onde foi possível pesquisar, essa é a única coleção de imagens anotadas para

²<https://www.kaggle.com/cihan063/autism-image-data> acesso em 5 de dezembro de 2022

³<https://www.kaggle.com/general/123978> acesso em 5 de dezembro de 2022

⁴<https://drive.google.com/drive/folders/1XQU0pluL0m3TIIxqtano12d68peMb8A?usp=sharing> acesso em 5 de dezembro de 2022

o problema que se tem conhecimento e portanto tem sido usada na literatura, conforme visto na Seção 2.

As imagens são armazenadas no formato JPEG, em cores, sendo classificadas em duas categorias: com autismo e sem autismo. As imagens estão divididas de forma balanceada, já separadas para fins de treinamento, validação e teste, como se segue:

- 2.528 amostras para treinamento, sendo 1.263 com autismo e 1.263 sem autismo;
- 200 amostras para validação, sendo 100 com autismo e 100 sem autismo; e
- 200 amostras para teste, sendo 100 com autismo e 100 sem autismo.

3.2. Visão Geral



Figura 1. Os cinco pontos de referência usados para extração de faces alinhadas, que é aplicado após a etapa de detecção. Fonte: <http://blog.dlib.net/> acesso em 20 de setembro de 2022




Figura 2. Face alinhada após o processo de extração, de modo que os olhos dos indivíduos são aproximadamente posicionados em uma mesma região de cada imagem usada no treinamento e ativação da CNN. Fonte: <http://blog.dlib.net/> acesso em 20 de setembro de 2022

A ideia utilizada se constrói no topo das técnicas de classificação. Cada imagem no *dataset* foi pré-processada usando técnicas viáveis para uma aplicação em tempo real.

Mais especificamente, buscou-se produzir faces com um tamanho padronizado e que estejam horizontalmente alinhadas. Isso permite que a CNN opere de forma mais eficiente no aprendizado da extração de representações, além de favorecer a confiabilidade dos resultados ao remover uma variabilidade capaz de introduzir uma complexidade desnecessária para o propósito de classificação.

O processo consiste em três etapas. Primeiro, um detector facial é aplicado na imagem de entrada, obtendo assim uma região retangular contendo os *pixels* do rosto do indivíduo. É importante ressaltar que nem sempre o detector é capaz de encontrar uma face na imagem, ocasionando a perda da amostra. Em seguida, essa região de interesse da imagem é recortada, sendo fornecida como entrada para um método de regressão que estima 5 pontos de referência da face (vide Figura 1). Note-se que, por se tratar de um regressor, essa segunda etapa sempre retorna os 5 pontos, a despeito da detecção facial. Contudo, a amostra é descartada para que não represente variação indesejada e interfira no processo de aprendizagem da CNN. Por fim, a imagem é transformada para um sistema de coordenadas de referência, produzindo uma face de dimensões e orientação conhecidas (vide Figura 2).

Finalmente, as imagens resultantes são usadas para conduzir o processo de treinamento do classificador desejado. No caso, será utilizada uma CNN simples do tipo sequencial com o intuito de verificar se é possível obter resultados competitivos com aqueles publicados na literatura ⁵.

4. Aspectos de Implementação

4.1. Extração de Faces Alinhadas

A extração de faces foi implementada em C++ usando a biblioteca *dlib*⁶. Trata-se de um *kit* de ferramentas escritas em C++ moderno que contém algoritmos e ferramentas de aprendizado de máquina para criar softwares que lidam com problemas do mundo real. Segundo os autores, é usado tanto na indústria quanto na academia em uma ampla gama de domínios, incluindo robótica, dispositivos embarcados, telefones celulares e grandes ambientes de computação de alto desempenho. Essa biblioteca foi selecionada por sua qualidade de implementação, boa documentação e disponibilidade de funcionalidades para processamento facial, destacando-se a detecção de faces, a obtenção de pontos de referência e extração de faces alinhadas a partir das informações anteriores.

Partindo das imagens originais do *dataset*, o processo de extração e alinhamento facial resultou em um conjunto ligeiramente inferior de imagens. Isso aconteceu porque o detector facial não foi capaz de localizar todas as faces presentes nas imagens, principalmente devido às limitações de ângulo e pose. Eis um sumário do resultado:

- 2.349 amostras para treinamento, sendo 1.158 (105 a menos) com autismo e 1.191 sem autismo (72 a menos);
- 186 amostras para validação, sendo 90 com autismo (10 a menos) e 96 sem autismo (4 a menos); e

⁵É importante salientar que testes preliminares foram realizados usando essa abordagem, recorrendo a um classificador do tipo SVM treinado com os vetores de características extraídos usando o modelo de *metric learning facial* da *dlib*. Contudo, essa abordagem não produziu resultados competitivos, obtendo 74,1% e 77,5% de acurácia média para as categorias de indivíduos com autismo e sem autismo, respectivamente.

⁶<http://dlib.net/> acesso em 20 de setembro de 2022

- 191 amostras para teste, sendo 93 com autismo (7 a menos) e 98 (2 a menos) sem autismo. Ou seja, foram descartadas 7 e 2 imagens com e sem autismo.

Assim, cada imagem usada nos experimentos foi redimensionada para conter 150 por 150 *pixels*. É importante observar que a cor preta foi usada para o preenchimento do fundo da imagem quando a região da face precisa ser rotacionada em vias de alinhar a face. Essa escolha se deveu ao fato de que também se pretende testar a viabilidade de produzir um classificador acoplado ao extrator de características usado originalmente para reconhecimento facial que é distribuído junto pelo projeto *dlib*.

4.2. Definição e Treinamento do Modelo CNN

O código-fonte para construção e treinamento do modelo foi desenvolvido em Python 3 usando TensorFlow versão 2, por meio da interface de alto nível Keras. Optou-se por utilizar um modelo do tipo sequencial, no qual as camadas são empilhadas umas sobre as outras, a partir da camada de entrada contendo os *pixels* da imagem. A quantidade de camadas, a quantidade de neurônios/convoluções e os parâmetros foram obtidos empiricamente.

A arquitetura é descrita como se segue:

- **Camada de Entrada.** Contém 150 por 150 *pixels* em RGB, ou seja, um tensor $150 \times 150 \times 3$;
- **Camada Convolutiva A.** Contém 16 convoluções 3×3 sem *padding* com ativação do tipo ReLU, seguida de *max pooling*. Essa é a camada com a menor quantidade de parâmetros;
- **Camada Convolutiva B.** Contém 32 convoluções 3×3 sem *padding* com ativação do tipo ReLU, seguida de *max pooling*;
- **Camada Convolutiva C.** Contém 16 convoluções 3×3 sem *padding* com ativação do tipo ReLU, seguida de *max pooling*;
- **Camada de Achatamento.** Converte as 16 saídas de 3×3 “pixels” em um vetor unidimensional com 4.624 componentes;
- **Camada Totalmente Conectada.** Contém 150 neurônios com ativação ReLU. Essa é a camada que concentra a maior quantidade de parâmetros do modelo (96% dos pesos) , porém produz um vetor contendo 150 características que poderão ser usadas na classificação final do padrão; e
- **Camada de Saída.** Resulta de 1 neurônios com função de ativação do tipo sigmoide.

Foi utilizado um treinamento sem necessidade de empregar técnicas de aumento de dados, pois o algoritmo não será aplicado em humanos nessa etapa preliminar da pesquisa, logo é desnecessário que a CNN capte sutilezas como variações na orientação, escala, ruído e distorções na cor das imagens faciais. Assim, foram utilizados os seguintes parâmetros:

- Por se tratar de um problema de classificação em duas classes, a função de perda escolhida para estimar o erro da CNN foi a entropia cruzada binária;
- Adotado o otimizador Adam, baseado no método SGD (Gradiente Descendente Estocástico), mas que estima os momentos de primeira e segunda ordem do gradiente para adaptar o *learning rate* que atualiza os pesos da rede neural durante o treinamento;

- Cada *mini-batch* usado para alimentar a CNN continha 32 imagens. Esse é um valor considerado razoável, pois reflete o limite máximo encontrado na literatura; e
- O treinamento foi realizado limitando-se a 100 épocas, utilizando 100 passos de validação.

5. Resultados e discussões

O experimento foi conduzido usando um computador pessoal, equipado com processador Intel Core i7-9750H CPU operando a 2,6GHz, com 16GM de memória RAM DDR4 operando a 2667 MHz e uma GPU GeForce GTX 1660 Ti Mobile com 6GB de memória.

A etapa de extração de faces foi realizada como o primeiro passo, levando menos de 5 minutos para produzir o resultado, visto que o protótipo demanda apenas 50ms em média para se extrair cada face. O *dataset* resultante contém apenas 45,8MB de imagens no formato JPEG. Como as fotos do conjunto de dados original continham poses tipicamente com predominância da face, a maioria das amostras demandou preenchimento com a cor do fundo. Também foi possível observar que diversas imagens apresentam poses em perspectiva, contendo faces rotacionadas para fora do plano, seja por estarem levemente de perfil, seja por estarem inclinadas para cima ou para baixo.

A etapa de treinamento da CNN tomou em média 2 horas, produzindo modelos com uma média de 82% de acurácia. Os arquivos contendo os pesos da rede neural resultante possuem um tamanho moderado, totalizando apenas 63,8 MB. Observou-se que a escolha de Keras e TensorFlow simplificou bastante o experimento, pois, além de oferecer uma interface de alto nível para definição dos modelos, permitiu um treinamento estável e também grande flexibilidade para carregar a CNN — tanto sua estrutura lógica quanto os pesos — nos *scripts* Python usados para avaliar seu desempenho com o *dataset* de teste. O tempo de inferência observado também foi surpreendentemente muito pequeno, pois o modelo leva em média apenas 15 ms para classificar uma imagem.

Com relação ao desempenho, os resultados podem ser considerados promissores. A acurácia média do modelo é de 82,7% para classificação em geral, sendo capaz de captar cerca de 81,9% das amostras de teste que correspondem a indivíduos com autismo (sensibilidade ou *recall*) e descartar corretamente 83,5% das amostras que de fato correspondem a indivíduos sem autismo (especificidade). Isso significa que o método pode ser considerado capaz de detectar moderadamente bem os casos de autismo, porém é limitado por ainda reportar cerca de 16,5% de falsos positivos.

	Classe Predita	
	Com Autismo	Sem Autismo
Amostras Com Autismo	77	17
Amostras Sem Autismo	16	81

Figura 3. Matriz de confusão para a CNN simples.

6. Considerações Finais

Partiu-se de uma perspectiva otimista, assumindo que qualquer tecnologia capaz de ajudar os pais a detectar precocemente distúrbios em seus filhos tem potencial de trazer benefícios à sociedade. Assim, esse trabalho versou sobre a avaliação da tecnologia de

redes neurais convolucionais para lidar com a detecção do autismo como um problema de classificação binária, i.e., a imagem facial fornecida como entrada é associada à categoria de “com autismo” e “sem autismo”. Note-se que é uma abordagem atraente para aplicações práticas, pois os níveis exigidos de colaboração e de intrusão dos pacientes para a utilização do método baseado na análise facial são mínimos.

É importante destacar que uma acurácia de 82,72% foi obtida para uma CNN relativamente simples, contendo menos de 704 mil parâmetros. Essa é uma *baseline* relativamente alta, principalmente levando em consideração a acurácia de 87% reportada por [Khosla et al. 2021] com uma arquitetura mais sofisticada.

Após uma série de pesquisas na internet, foi encontrado um *dataset* que continha as imagens necessárias para o trabalho aqui discutido. Com esses dados brutos foi iniciado o desenvolvimento da CNN, os parâmetros utilizado para construir a CNN foram obtidos empiricamente

6.1. Ameaças à Validade

Conforme mencionado, o *dataset* utilizado pode apresentar questionamentos sobre sua construção e disponibilização na comunidade do Kaggle. É necessário observar que, questões das quais nos isentaremos assumindo que foram seguidos os aspectos éticos nos meios de publicação que veicularam pesquisas usando essa base de imagens – mais especificamente, o trabalho se isenta da discussão sobre o periódico Brain Sciences ser predatório ou não.

Devido à carência de evidências para tanto, não se pode assumir que toda e qualquer imagem no *dataset* utilizado está rotulada corretamente. Além disso, também não se pode afirmar que essa coleção seja estatisticamente relevante para pautar adequadamente uma discussão sobre aspectos étnicos, regionais e sazonais, dentre outros, que considerem a generalização dos resultados ora reportados.

Por fim, não foi possível exaurir todas as possibilidades de redes neurais, algoritmos, parâmetros, etc, por não se tratar de uma pesquisa devidamente financiada e com os recursos necessários para tanto.

6.2. Trabalhos Futuros

Em primeiro lugar, é importante intensificar a busca por evidências de que possa (ou não) haver relação entre características faciais e outros exames que reflitam os traços do autismo. Uma extensão direta deste trabalho deve considerar outros tipos de classificadores, bem como arquiteturas de redes neurais. Além disso, é fundamental que sejam realizados esforços transparentes para a construção de novos e mais expressivos conjuntos de dados com imagens faciais, capazes de prover maior capacidade de análise e generalização para os resultados das pesquisas futuras. Por fim, também é importante considerar a criação de bases de dados multimodais para lidar com o desafio de detectar o autismo automaticamente. É importante notar que o protótipo ora desenvolvido demonstrou a viabilidade de seu uso em tempo real para produzir uma combinação com dados de outros exames, terapias e intervenções.

Referências

- Akter, T., Ali, M. H., Khan, M., Satu, M., Uddin, M., Alyami, S. A., Ali, S., Azad, A., Moni, M. A., et al. (2021). Improved transfer-learning-based facial recognition framework to detect autistic children at an early stage. *Brain Sciences*, 11(6):734.
- Alchalabi, A. E., Shirmohammadi, S., Eddin, A. N., and Elsharnouby, M. (2018). Focus: Detecting adhd patients by an eeg-based serious game. *IEEE Transactions on Instrumentation and Measurement*, 67(7):1512–1520.
- Di Martino, A., Yan, C.-G., Li, Q., Denio, E., Castellanos, F. X., Alaerts, K., Anderson, J. S., Assaf, M., Bookheimer, S. Y., Dapretto, M., et al. (2014). The autism brain imaging data exchange: towards a large-scale evaluation of the intrinsic brain architecture in autism. *Molecular psychiatry*, 19(6):659–667.
- Hosseini, M.-P., Beary, M., Hadsell, A., Messersmith, R., and Soltanian-Zadeh, H. (2022). Deep learning for autism diagnosis and facial analysis in children. *Frontiers in Computational Neuroscience*, 15.
- Khosla, Y., Ramachandra, P., and Chaitra, N. (2021). Detection of autistic individuals using facial images and deep learning. In *2021 IEEE International Conference on Computation System and Information Technology for Sustainable Solutions (CSITSS)*, pages 1–5.
- LeCun, Y., Bengio, Y., and Hinton, G. (2015). Deep learning. *nature*, 521(7553):436–444.
- Loo, S. K. and Makeig, S. (2012). Clinical utility of eeg in attention-deficit/hyperactivity disorder: a research update. *Neurotherapeutics*, 9(3):569–587.
- Mujeeb Rahman, K. K. and Subashini, M. M. (2022). Identification of autism in children using static facial features and deep neural networks. *Brain Sciences*, 12(1).
- Russell, S. J. (2010). *Artificial intelligence a modern approach*. Pearson Education, Inc.
- Trevarthen, C. (1998). *Children with autism: Diagnosis and interventions to meet their needs*. Jessica Kingsley Publishers.
- Zhang, Y., Kong, M., Zhao, T., Hong, W., Xie, D., Wang, C., Yang, R., Li, R., and Zhu, Q. (2021). Auxiliary diagnostic system for adhd in children based on ai technology. *Frontiers of Information Technology & Electronic Engineering*, 22(3):400–414.

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

- L698d Lima Junior, Graciano Barbosa.
Detecção de Autismo em Imagens Faciais usando Redes Neurais Convolucionais / Graciano Barbosa
Lima Junior. – 2022.
9 f. : il. color.
- Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Instituto UFC Virtual,
Curso de Sistemas e Mídias Digitais, Fortaleza, 2022.
Orientação: Prof. Dr. José Gilvan Rodrigues Maia.
1. Redes Neurais Convolucionais. 2. classificação de imagens. I. Título.

CDD 302.23
