

DECIFRANDO SENTIMENTOS: TECNOLOGIA DE ANÁLISE FACIAL PARA AUTISTAS

ALINE ROCHA DOS SANTOS¹
WILLIAN MARTINS JUSTIMIANO¹
ELIANE VENDRAMINI DE OLIVEIRA¹

RESUMO

A integração social de pessoas com o Transtorno do Espectro Autista (TEA) é um desafio significativo devido às dificuldades que essas pessoas enfrentam em socialização, comunicação e aprendizagem. Uma área crítica é a representação emocional, onde pessoas com TEA têm dificuldades em assumir e expressar emoções, especialmente por meio de expressões faciais, o que torna a comunicação social ainda mais desafiadora. Para abordar essa necessidade, foi desenvolvido um protótipo de aplicação que utiliza técnicas de aprendizado de máquina para detectar sentimentos em pessoas, com o objetivo de promover a inclusão social de indivíduos com TEA. A aplicação utiliza uma câmera de um celular para capturar as expressões faciais de uma pessoa, analisando-as e informando ao usuário autista qual o sentimento que está sendo expresso. Isso facilita a compreensão do autista ao relacionar o sentimento identificado pelo aplicativo com as expressões faciais correspondentes, proporcionando maior autonomia de convívio e demonstrando suas capacidades. A tecnologia utilizada inclui uma Rede Neural Convolucional (CNN), uma forma de inteligência artificial especializada em análise de imagens. A base de dados para o treinamento da rede neural foi retirada do Kaggle, composta por fotos de rostos. Os resultados mostraram uma acurácia de 78,85% após 50 temporadas de treinamento, o que possibilita a classificação de emoções em tempo real. Essa aplicação representa um avanço significativo na redução das barreiras sociais para pessoas com TEA, ao auxiliar na interpretação de emoções.

Palavras-chave: Autismo; Rede Neural Convolucional; Imagem; Sentimentos.

ABSTRACT

The social integration of people with Autism Spectrum Disorder (ASD) is a significant challenge due to the difficulties these people face in socialization, communication and learning. A critical area is emotional representation, where people with ASD have difficulty assuming and expressing emotions, especially through verbal expressions, which makes social communication even more challenging. To address this need, an application prototype was developed that uses machine learning techniques to detect feelings in people, with the aim of promoting the social inclusion of individuals with ASD. The application uses a cell phone camera to capture a person's facial expressions, analyzing them and informing the autistic user what feeling is being expressed. This facilitates the autistic person's understanding by relating the feeling identified by the application with the corresponding verbal expressions, providing greater autonomy in coexistence and demonstrating their capabilities. The technology used includes a Convolutional Neural Network (CNN), a form of artificial intelligence specialized in image analysis. The database for training the neural network was taken from Kaggle, consisting of photos of faces. The results showed an accuracy of 78.85% after 50 training seasons, which makes it possible to classify emotions in real time. This application represents a significant advance in reducing social barriers for people with ASD, by assisting in the interpretation of emotions and improving.

Keywords: Autism; Convolutional Neural Network; Image; Emotions.

¹ Faculdade de Tecnologia de Adamantina (Fatec), Adamantina-SP, Brasil

1 INTRODUÇÃO

Diversos estudos sobre o Transtorno do Espectro Autista (TEA) foram realizados ao longo dos anos, focando em distúrbios do neurodesenvolvimento, como comunicação social e comprometimento intelectual, que se manifestam antes dos três anos (FERREIRA, 2016). As pesquisas abordam temas como genética, terapias e a eficácia de tratamentos farmacêuticos, mas a inclusão e readaptação social dos indivíduos com TEA são tópicos menos frequentes. Essas pessoas apresentam dissemelhanças, como dificuldades na comunicação, na compreensão de expressões faciais, rigidez cognitiva e comportamentos estereotipados (RIBEIRO, 2020). Embora existam técnicas de treinamento para melhorar a interação social, nem todos os indivíduos com TEA têm acesso a essas informações, e muitos adultos não tiveram essa oportunidade, pois as técnicas ainda não estavam disponíveis (OPAS, 2024).

Este trabalho tem o objetivo de promover a inclusão de indivíduos com TEA nas relações em sociedade, dando-lhes autonomia de convívio, e provando suas capacidades, competências e habilidades para a sociedade, isto é, auxiliar na diminuição da barreira de convívio social, oferecendo a possibilidade de interpretação do outro indivíduo participante da interação identificando técnicas de aprendizado de máquina eficiente para análise de sentimento humano através de expressões faciais em imagens.

E a fim de auxiliá-los no relacionamento humano, já que não detém percepção em relação a emoção das outras pessoas observando o rosto, é proposto uma ferramenta para auxiliá-los nessa simples função, mas trazendo grandes benefícios para a pessoa com transtorno do espectro autista, pois com a mesma, identifica-se o que a pessoa com quem está conversando por exemplo está sentindo naquele momento, é possível manter uma conversa ou relacionamento mais envolvente, responsável, respeitoso, assertivo, prazeroso, entre tantas outros sentimento gratificantes que ambos terão ao entender melhor o que o outro está sentindo.

Exemplificando melhor, uma pessoa pode estar tendo problemas, e o portador de TEA dizer algo não muito agradável, não por mal, mas por não ter essa percepção, e com a ferramenta, podendo identificar a emoção do outro, acabaria podendo até ter uma palavra de apoio, sendo muito mais interessante em uma amizade. O algoritmo terá como base a análise de imagens, através de treinamento de um banco de dados com imagens classificadas por

sentimento, e realizando a leitura do rosto, o software pode indicar com os sentimentos a pessoa em questão está sentindo no momento, através da análise de microexpressões faciais.

A pesquisa aqui apresentada tem como propósito, por meio de um algoritmo para classificação de imagens treinado com a base de dados contendo inúmeras imagens de feições com expressões diferentes, treinar um sistema onde, toda vez que uma câmera for apontada para o rosto de um indivíduo, ele categorize sua emoção, mostrando assim para seu usuário que tipo de sentimento está sendo apresentado. Isso possibilitaria uma melhor análise além de auxiliar no desenvolvimento social e interativo dele.

Eles [estados emocionais] são os afetos que surgem súbita e involuntariamente (se pode dizer: eu fiquei com raiva, a alegria me dominou); ademais, estas emoções propriamente ditas, são estados primordialmente ideativos e situacionais, com os quais estão relacionados sentimentos objetais, ou seja, utilizando uma expressão figurada de Stendhal, vivências emocionais estáveis, “cristalizadas” no objeto; [...]. Sem entrar na análise destas distintas classes de estados emocionais, assinalemos somente que eles entram em complexas relações mútuas: o pequeno Rostov antes do combate temia – e esta é uma emoção – ser dominado pelo medo (LEONTIEV, 1975, p. 164).

No caso de indivíduos com TEA a dificuldade em interpretar essas emoções pode ser um impedimento significativo para a interação social. Ao aprimorar a capacidade desses indivíduos de reconhecer e corresponder adequadamente às emoções alheias, essa abordagem pode promover uma maior inclusão e adaptação social, melhorando a qualidade de vida e facilitando a integração social dos indivíduos com TEA.

2 FUNDAMENTAÇÃO TEÓRICA

Este trabalho se fundamenta em técnicas, algoritmos e estudos que desempenham um papel essencial na sua construção, garantindo princípios teóricos sólidos e comprovados. Essas abordagens não só suportam a prática, mas também asseguram precisão, eficiência e alinhamento com as melhores práticas e inovações do campo de estudo.

2.1 Análise de sentimento baseado em imagens

A análise de sentimento, um subcampo do Processamento de Linguagem Natural (PLN), visa extrair informações de grandes volumes de dados não estruturados, identificando a polaridade semântica de frases e lidando com ambiguidades em inteligência artificial (MOUTHAMI & BHASKARAN, 2013). Com o crescimento das mídias sociais, a análise de sentimentos abrange também dados de imagens, coletando perfis e analisando expressões diversas com algoritmos de Deep Learning (DL), uma área de *Machine Learning* focada em representar dados complexos (Goodfellow; Bengio; Courville, 2016; Khamparia; Singh, 2019; Leijnen; Salehi; Burgueño, 2018; Veen, 2020). O Deep Learning permite que o sistema aprenda a partir de exemplos, utilizando camadas de neurônios que, em etapas, extraem e identificam padrões complexos nos dados (BURGUEÑO, 2018).


2.2 Redes neurais

Redes neurais (RN) simulam o funcionamento do cérebro humano usando componentes eletrônicos ou simulações computacionais. Elas consistem em células computacionais chamadas neurônios, organizadas em camadas para garantir um bom desempenho. Uma RN típica possui três tipos principais de camadas.

A *Input Layer* é a camada inicial de uma rede neural, onde os dados brutos são inseridos e cada neurônio representa uma característica do conjunto de dados. A *Hidden Layer* (ou camada oculta) consiste em uma ou mais camadas intermediárias que processam a informação, com cada neurônio conectado aos neurônios da camada anterior, realizando cálculos complexos. Por fim, a *Output Layer* é a camada final, que executa a previsão ou classificação, com o número de neurônios ajustado ao tipo de problema a ser resolvido (HAYKIN, 2008).

A figura 1 apresenta o funcionamento de uma rede neural com suas três camadas em ação: uma camada de entrada, 2 camadas de processamento e a última camada de resultado.

Figura 1 – Rede neural



Fonte: (OLIVEIRA, 2010)

2.2.1 Perceptron

O *perceptron* é o componente mais básico de uma rede neural, consistindo em um neurônio com entradas e saídas. Ele é definido por um conjunto de valores de entrada (E) e pesos (P). O processamento do *perceptron* envolve as etapas de programação e ativação, que geram o resultado do neurônio (KRIESEL, 2007)

Segundo Kovács (2006), a etapa de propagação do *perceptron* gera um escalar α através do cálculo que combina os valores de entrada (E) e pesos (P) por multiplicação e soma. O resultado, f_{prop} , é processado pela função de ativação, que imita a sinapse do cérebro humano, determinando se a informação será transmitida ao próximo neurônio. A função de ativação aplica um valor limitante para decidir se o sinal será passado adiante.

A Figura 2 mostra a arquitetura de um *perceptron*, que transmite a informação ao próximo neurônio, onde a função de ativação decide se a informação será passada adiante.

Figura 2 – Etapas de um perceptron e sua arquitetura



Fonte: Autoria própria


2.2.2 Rede neural convolucional

A Rede Neural Convolucional (CNN) é uma variação das redes de perceptrons de múltiplas camadas, projetada principalmente para processar dados visuais, atuando de forma similar à visão computacional. A visão computacional, uma área relativamente recente com início em 1955, permite que computadores "vejam" e compreendam o ambiente ao seu redor por meio de scanners, sensores, fotos e vídeos, extraindo informações para análise (HONORATO, 2010).

Para entender o que uma CNN realiza, é essencial compreender o conceito de imagem digital. Uma imagem capturada é transferida para o computador como um sinal bidimensional contínuo, estruturado em um retângulo no qual cada posição no plano contém informações que formam a imagem, sendo o domínio o plano e o contradomínio o espaço de cor (SCURI, 1999).

A Figura 3 apresenta como ocorre a transformação de uma imagem fotográfica a uma imagem codificada, ou seja, como ocorre sua pixelização e vice e versa.

Figura 3 –Imagem continua



Fonte: (SCURI, 1999)

Segundo Scuri (1999), a função utilizada para modelar matematicamente imagens contínuas é gerada a partir de duas variáveis que são x e y sendo elas números reais estabelecidos no intervalo de 0 a X , e 0 a Y .

$$f(x, y) = \text{cor no ponto}(x, y)$$


$$x \in [0, X] \text{ e } y \in [0, Y]$$

Após se implementar a função tem-se a geração de uma matriz de $M \times N$ segundo a quantização do valor de $f(x, y)$ em níveis de cinza.

De acordo com Balan (2009), é na etapa de amostragem na qual a segmentação do plano x, y em uma grade no qual os pontos pertencentes a esta divisão são reconhecidos como pixels, que são elementos da imagem, sendo eles elementos pertencentes da imagem original, mas com valores proporcionais a $M \times N$ na matriz.

A figura 4 descreve de forma visual etapa por etapa como ocorre a transformação da imagem contínua que foi previamente processada para sua versão em matriz.

Figura 4- Etapas do processamento de uma imagem



Autor: (SCURI, 1999)


Em relação à estruturação de uma CNN, são necessários alguns elementos para sua composição, sendo elas as camadas de convolução, camadas de *pooling* que é uma técnica que simplifica dados em redes neurais ao reduzir sua dimensão, mantendo informações essenciais, e camadas conectadas, onde por meio delas podem ser extraídas *features*, que são características ou atributos relevantes dos dados usados para treinar modelos de *machine learning*.

A camada de convolução é responsável por extrair as principais características das imagens de entrada, ajustando filtros durante o treinamento para identificar padrões como cores e arestas. O aumento do número de camadas melhora a extração de *features*, tornando o modelo mais

eficaz no reconhecimento de padrões, mas exige maior poder computacional e tempo de análise. É importante equilibrar o número de camadas para evitar o *overfitting*, quando o modelo se ajusta demais aos dados de treinamento, e o *underfitting*, quando é muito simples para captar padrões (O'SHEA; NASH, 2015).

A Figura 5 ilustra passo a passo o processo de uma Rede Neural Convolucional, desde a conversão da imagem em escala de cinza até sua transformação em matriz e extração dos detalhes mais relevantes.

Figura 5- Estrutura visual de um Rede Neural Convolucional




Fonte: (PONTI; COSTA, 2017)

É utilizada uma técnica chamada *Pooling* para simplificar dados em redes neurais, reduzindo sua dimensão e mantendo informações essenciais. Ela analisa as características da etapa de convolução para reduzir a dimensão dos dados, focando nos aspectos mais marcantes, o que minimiza o gasto computacional e diminui o *overfitting* (O'SHEA; NASH, 2015).

Conforme a Figura 6, a execução de *pooling* começa com a definição do tamanho do passo (*stride*). Em seguida, escolhe-se entre as técnicas *Max*, que seleciona o valor máximo de uma região específica da imagem, ou *Average*, que calcula a média dos valores em uma região específica. Neste trabalho, foi utilizada a técnica *Max*, que considera o melhor resultado de cada região da imagem. Isso resulta na geração de um novo conjunto de dados reduzido, visando melhorar o desempenho da rede (O'SHEA; NASH, 2015).

A figura 6 detalha a técnica de *Pooling*, com as vertentes *Max* e *Average*.

Figura 6 – Técnica de Pooling



Autor: (YINGGE; ALI; KANG, 2020)

A etapa de Multicamadas conectadas é a fase final da arquitetura convolucional, composta por *perceptrons* em camadas que processam os dados resultantes das etapas de convolução e *pooling*, classificando-os nas *labels* que a rede foi treinada para identificar ou prever.

2.3 Métricas para validação

A acurácia é uma métrica que mede a proporção de previsões corretas (tanto positivas quanto negativas) em relação ao total de previsões, considerando os rótulos classificados como positivos (TP), negativos (TN), falsos positivos (FP), e falsos negativos (FN) (POWERS, 2020).

3 TRABALHOS CORRELATOS

Segundo G. Castro et al. (2019) uma base de dados de 1000 imagens para reconhecimento de sinais de Libras, alcançando 72,6% de acurácia com uma CNN 3D.

Garcia (2021) explorou a detecção de emoções em imagens com *hardware*

limitado, usando redes neurais e obtendo 68,5% de acurácia. Em Andrade et al. (2021) combinaram descritor de Fourier e KNN para classificar formas, alcançando uma acurácia máxima de 60%. Em Junior e Pacheco (2023) mapearam a cobertura do solo em Pernambuco usando SVM, com a imagem MUX obtendo 71,74% de acurácia.

A Tabela 1 compara a eficácia dos métodos de classificação de imagens, destacando a técnica com melhor acurácia.

Tabela 1 – Taxa de acerto em Percentual de trabalhos com Classificação de Imagens

Autores	Método	Acurácia
CASTRO, G. et al. (2019).	CNN, sumarização	72,6
GARCIA (2021)	CNN	68,5
ANDRADE et al. (2021).	KNN	60
S. JUNIOR; PACHECO (2023)	SVM	71,74

Fonte: Autoria própria

4 METODOLOGIA

Para o avanço deste estudo foi desenvolvido uma estrutura de ordenação metodológica para criação do sistema.

4.1 Base de dados

Com a linha de pensamento definida, foi necessário encontrar uma base de dados adequada, obtida no site *Kaggle*. A base selecionada foi o "*Face Expression Recognition Dataset*", que contém dados divididos em classes emocionais: *angry*, *disgust*, *fear*, *happy*, *neutral*, *sad* e *surprise*. Após encontrar a base de dados, foi realizado um pré-processamento que incluiu o reenquadramento das imagens para 48x48 pixels, a transformação dos pixels em valores inteiros (0 a 255), e a normalização desses valores para a faixa de 0 a 1 em ponto flutuante.

4.2 Implementação da Modelo Rede Neural Convolucional

Foi configurado o *Google Colab* e preparado *links* aos quais facilitariam o acesso aos dados da base, definindo caminhos específicos para os diretórios de entrada no ambiente *Kaggle*. Para processar as imagens foi utilizado a classe “*ImageDataGenerator*” do *TensorFlow*, foi configurado um gerador de conjunto de treinamento o qual suas principais funções são normalizar os dados e geração de novos dados.

Na compilação do modelo:


- Foram criadas três camadas convulsionais sendo de 32, 64 e 128 filtros, todas utilizando a função “*relu*”.
- Após as camadas convolucionais foram produzidas camadas de *pooling* para redução de dimensão.
- Criação de camadas densas com 512 neurônios, seguida de uma camada de *dropout* que é uma técnica que desativa aleatoriamente neurônios durante o treinamento para prevenir *overfitting* e melhorar a generalização do modelo.
- Por fim produção da camada de saída com 4 neurônios um para cada classe de emoção, e função de ativação *softmax* que é uma função que transforma valores em probabilidades, usada para classificação em redes neurais para classificação *multiclass* que se refere a problemas de classificação onde há mais de duas classes possíveis.

No treinamento do modelo ela passou pela quantidade de 50 épocas a cada época, avaliamos o desempenho do modelo nos dados de validação para monitorar o progresso e evitar *overfitting*.

Com a finalidade de avaliação do modelo, foi se calculado as métricas de perda em 45,50%, acurácia de treino de 80% e acurácia de teste em 78, 85% conforme apresentado na figura 7.


Para maior entendimento do modelo, foi plotado uma matriz de confusão demonstrado na figura 8 na qual é possível notar que o modelo consegue prever de maneira satisfatória as expressões de felicidade e de maneira normal os demais expressões.

Figura 7 – Visualização de acurácia e treinamento



Fonte: Autoria própria

Figura 8 – Matriz de confusão



Autor: Autoria própria

Por fim houve salvamento do modelo treinado no formato HDF5(.h5) para ser utilizado na aplicação final.

4.3 Desenvolvimento da aplicação final

Para o desenvolvimento da aplicação, utilizou-se diversas bibliotecas, como *Keras* e *OpenCV*, sendo elas necessárias para o carregamento do modelo criado anteriormente e para a captura de imagem em tempo real, leitura de frames e por fim conversão de cores. Sequencialmente é feito o carregamento de modelos essenciais sendo eles a rede neural previamente treinada e o modelo cascata responsável pela detecção de rostos.

Com a implementação realizada, define-se uma lista contendo as 6 classes de emoções: 'Raiva', 'Medo', 'Feliz', 'Neutro', 'Triste' e 'Surpresa'. Estas classes serão aplicadas para mapear as predições do modelo para rótulos compreensíveis.

Definidas as classes, pode-se iniciar a captura de imagem fazendo uso da função "*VideoCapture*", onde inicialmente ocorrerá o processamento frame em um loop contínuo composto pelas seguintes etapas: leitura do frame, conversão do frame para escala de cinza para facilitar a detecção, com o frame é possível

a detecção de rostos.

Após cada rosto detectado, é hora do processamento deles, onde é marcado com um retângulo. Feito isto, é realizada a extração e redirecionamento (ROI) da imagem em 48x48 pixels na região do rosto com o propósito de deixar igual ao modelo de classificações de imagem.

Com as extrações do ROI realizadas, verifica-se se o ROI não está vazio e a conversão para *array* tornado o compatível com outros modelos. Agora o ROI se encontra pré-processado chega à etapa da predição de emoções onde o modelo de rede neural convolucional predirá emoção presente no ROI e aparecerá escrito qual é a emoção de acordo com a figura 9.

Figura 9 – Resultado da aplicação exibindo a captação do ROI (retângulo amarelo), e instantaneamente, o sentimento interpretado.

Figura 9 – Resultado da aplicação



Autor: Autoria própria

5 CONCLUSÃO

Desenvolver uma aplicação para identificar emoções a partir de imagens faciais, visando à inclusão e readaptação social de pessoas com autismo na sociedade e à evolução das técnicas atuais tem propósito nobre e satisfatório em meio social e tecnológico. Os resultados obtidos apresentaram uma taxa de classificação de 78,85% das emoções, demonstrando que a abordagem escolhida foi eficaz. Foram aplicadas técnicas de classificação de imagem e *Deep Learning*, o que permitiu alcançar esse desempenho significativo.

Essa aplicação apresenta resultados promissores, apesar de reconhecer que ainda há desafios a serem superados, incluindo o fato de que ainda não foi implantada no contexto do mundo real, sabendo que os dados adquiridos e a usabilidade em diferentes situações e com diversas populações reagem de maneiras diferentes.

Em conclusão, o presente estudo representa um avanço na tecnologia para o âmbito humano e social. Acredito que isso futuramente a tornará uma ferramenta para apoiar a inclusão social de pessoas com autismo, auxiliando-as a construir conexões mais fortes e significativas no mundo ao seu redor.

REFERÊNCIAS

ANDRADE, Vinicius Santos et al. **Classificador de formas utilizando descritor de Fourier usando distância do centroide**. Fatec Ourinhos, 2021. Disponível em: <https://www.fatecourinhos.edu.br/retec/index.php/retec/article/view/403/270>. Acesso em: 07 jul. 2024.

BALAN, Willians Cerozzi. **A imagem digital**. Apostila, UNESP, São Paulo, SP, Brasil, 2019. Disponível em: http://willians.pro.br/textos_publicados/A%20Imagem%20Digital%20-%20Willians%20Cerozzi%20Balan.pdf. Acesso em: 2 jul. 2024.

CASTRO, Giulia Z. de et al. **Desenvolvimento de uma base de dados de sinais de Libras para aprendizado de máquina: estudo de caso com CNN 3D**. In: Simpósio Brasileiro de Automação Inteligente, 2019. Disponível em: <https://encurtador.com.br/GMrDk>. Acesso em: 07 jul. 2024.

FERREIRA, Jackeline Tuan Costa et al. **Efeitos da fisioterapia em crianças autistas: estudo de séries de casos**. Cadernos de Pós-Graduação em Distúrbios do Desenvolvimento, v. 16, n. 2, São Paulo, dez. 2016. Disponível em: http://pepsic.bvsalud.org/scielo.php?script=sci_arttext&pid=S1519-03072016000200005. Acesso em: 27 jun. 2024.

GARCIA, Lucas Henz. **Deteção de emoções utilizando redes neurais convolucionais em sistemas com recursos limitados de hardware**. Universidade Federal do Rio Grande do Sul, Escola de Engenharia, Departamento de Engenharia Elétrica, 2021. Disponível em: <https://lume.ufrgs.br/bitstream/handle/10183/234173/001134980.pdf?sequence=1&isAllowed=y>. Acesso em: 07 jul. 2024.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep learning**. Cambridge: MIT Press, 2016.

HAYKIN, Simon. **Neural Networks and Learning Machines**. 3. ed. New York: Prentice Hall, 2008. p. 21.

KOVÁCS, Zsolt László. **Redes neurais artificiais: fundamentos e aplicações**. 4. ed. São Paulo: Livraria da Física, 2006. p. 31.

LEONTIEV, A. N. **Actividad, consciencia y personalidad**. Havana: Editorial Pueblo y Educación, 1975. p. 164.

OLIVEIRA, Anderson Castro Soares de; SOUZA, Ademária Aparecida de; LACERDA, Wilian Soares; GONÇALVES, Luciene Resende. **Aplicação de redes neurais artificiais na previsão da produção de álcool**. Universidade Federal de Lavras/UFLA, 2010. Disponível em: https://www.researchgate.net/publication/240772105_Aplicacao_de_redes_neurais_artificiais_na_previsao_da_producao_de_alcool. Acesso em: 09 jul. 2024.

PONTI, Moacir A.; PARANHOS DA, Gabriel B. **Como funciona o Deep Learning**. Cornell University, 2018. Disponível em: <https://arxiv.org/abs/1806.07908>. Acesso em: 04 jul. 2024.

ORGANIZAÇÃO PAN-AMERICANA DA SAÚDE. **Transtorno do espectro autista**. Disponível em: <https://www.paho.org/pt/topicos/transtorno-do-espectro-autista>. Acesso em: 11 ago. 2024.

RIBEIRO, Amanda Gracielly. **Impacto psicológico da família ao receber o diagnóstico de autismo**. 2020. Disponível em: <http://104.207.146.252:8080/xmlui/handle/123456789/548>. Acesso em: 17 ago. 2024.

SALEHI, Hadi; BURGUEÑO, Rigoberto. **Emerging artificial intelligence methods in structural engineering**. Engineering Structures, United Kingdom, v. 171, p. 170-189, 2018. Disponível em: <https://doi.org/10.1016/j.engstruct.2018.05.084>. Acesso em: 25 set. 2021.

SCURI, Luís Marcelo Paschoal. **Notas de aula: curso de CGI**. 1999. Disponível em: https://www2.tecgraf.puc-rio.br/ftp_pub/curso-cgi/Notas_de_Aula/scuri.pdf. Acesso em: 13 ago. 2024.

SILVA JÚNIOR, Juarez Antônio da; PACHECO, Admilson da Penha. Classificador Support Vector Machines para o mapeamento da cobertura do solo usando imagens CBERS-4/MUX e Landsat-8/OLI. **Revista Brasileira de Geografia Física**, v. 16, 2023. Disponível em: <https://periodicos.ufpe.br/revistas/index.php/rbgfe/article/view/257409/43877>. Acesso em: 09 jul. 2024.

SIQUEIRA, Lucas Pavanelo. **Identificação e classificação de lixo doméstico através de rede neural convolucional**. Porto Alegre: Universidade Federal do Rio Grande do Sul, Escola de Engenharia, Departamento de Engenharia Química, novembro de 2021. Trabalho de Conclusão de Curso em Engenharia Química. Disponível em: <https://lume.ufrgs.br/handle/10183/235795>. Acesso em: 08 jul. 2024.

TRIPATHY, Abinash; AGRAWAL, Ankit; RATH, Santanu Kumar. **Classification of sentimental reviews using machine learning techniques**. In: International Conference on Recent Trends in Computing, 3., 2015, [Local da conferência]. Proceedings of the 3rd International Conference on Recent Trends in Computing. ELSEVIER, 2015. Disponível em: <https://core.ac.uk/download/pdf/82667502.pdf>. Acesso em: 1 jul. 2024.

YINGGE, Huo; ALI, Imran; LEE, Kang-Yoon. **Deep neural networks on chip - a survey**. IEEE, Busan, Korea (South), 2020. Disponível em: <https://ieeexplore.ieee.org/abstract/document/9070243>. Acesso em: 19 jun. 2024.