



A Computação Afetiva (CA) é um campo emergente da Inteligência Artificial (IA) surgido na década de 90 com a professora Rosalind Picard do MIT (Massachusetts Institute of Technology). Esta área de estudo dedica-se ao desenvolvimento de sistemas capazes de reconhecer, interpretar e processar os sentimentos humanos, suas emoções (CORTIZ; SANTOS, 2022). Conforme Bercht (2006) o atraso no interesse de muitos pesquisadores acerca desta área se deve em virtude da complexidade do estudo das emoções, da dicotomia que existiu entre a razão e a afetividade nas ciências exatas, e dos obstáculos computacionais enfrentados no âmbito da lógica e dos formalismos essenciais. Além disso, a capacidade operacional do ambiente e das ferramentas existentes, para executar esse tipo de programação, também foi um desafio significativo.

Com a ruptura do paradigma entre a razão e a emoção, nas ciências exatas, juntamente com a percepção da importância de ambas para a tomada de decisão, a CA conseguiu evoluir significativamente, acompanhando os avanços tecnológicos, enquanto o interesse acadêmico e industrial pelo assunto aumentava (CORTIZ; SANTOS, 2022). Assim, os estudos sobre CA expandiram, e as tecnologias progrediram de modo a conceber diversos ambientes e linguagens de programação capazes de armazenar e executar dados da CA, um desses é a Rede Neural Convolucional (CNN) definida por Goodfellow, Bengio e Courville (2017) como um tipo de rede neural com capacidade de processar dados em grade, como as imagens.

Em virtude disso, pode-se citar trabalhos como o de Chiu *et al.* (2020), que buscou automatizar a detecção de usuários com tendências depressivas no *Instagram*, alcançando 82% de acertos. E o trabalho de Montay e Urquhart (2022), que desenvolveram um sistema de monitoramento para automóveis com o propósito de mensurar as reações do corpo, auxiliando na segurança e traçando um perfil dos passageiros para melhorar suas experiências durante a viagem.

Ainda assim, a CA abrange uma ampla gama de áreas e temas, tanto os já explorados quanto os ainda não investigados, incluindo o ambiente educacional. Isso ocorre em razão do constante surgimento de novas demandas e desafios exigindo inovação e adaptação contínua, conforme pode ser observado em Cortiz e Santos (2022) e Bercht (2006).

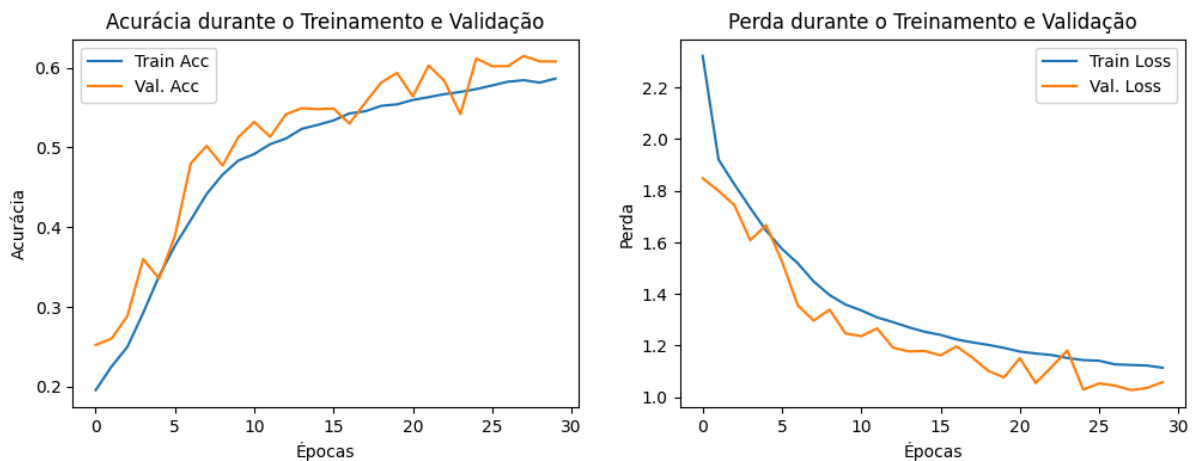


características próprias que as distinguem das demais possibilitando sua identificação por meio do aprendizado de máquina.

Não obstante, Andrade e Abreu (2013) sugerem a introdução de mais uma expressão, a expressão neutra desprovida de qualquer emoção expressiva. Além disso, semelhante a Miguel (2015) e Ekman (2003), as proposições e fundamentos teóricos trazidos por Andrade e Abreu (2013) explicitam a teoria das emoções básicas dialogando sobre a conjectura acerca das emoções serem capazes de gerar reações únicas na fisionomia do corpo. Deste modo, pessoas de etnias, culturas, regiões e idiomas diferentes podem apresentar a mesma reação física ao vivenciar momentos onde acabam reagindo por meio das emoções básicas.

Neste contexto, foi desenvolvida uma CNN com o propósito de classificar emoções básicas a partir de expressões faciais. Para avaliar o desempenho da CNN, analisou-se as curvas de treinamento e teste, focando em padrões de validação, convergência de épocas (*epochs*) e o risco de *overfitting*. As métricas de desempenho consideradas incluem a perda (*train loss*) e a acurácia (*train acc*) do conjunto de treinamento, além da perda (*val. loss*) e da acurácia (*val. acc*) do conjunto de validação.

Figura 1: Treinamento e Validação da CNN.



Fonte: Autora, 2024.

Ao analisar os dados obtidos ao longo de 30 épocas pela CNN, é possível identificar algumas tendências no desempenho do modelo. Na primeira época, a perda de treinamento (*train loss*) foi alta, atingindo 2,3229, enquanto a acurácia (*train acc*) foi baixa, em torno de 19,56%. Em relação à perda de validação (*val. loss*) na mesma época, o valor registrado foi de



manifestações visíveis de estados emocionais internos e, por isso, podem apresentar variações sutis, dificultando sua identificação através do aprendizado de máquina.

Por conseguinte, ao trabalhar com o processamento de imagens é necessário estar atento aos detalhes, apresentar um processamento padronizado e um ambiente computacional complexo que seja capaz de extrair as características individuais dessas imagens, identificar sua classificação perante as classes criadas e aprender padrões associados aos dados previamente informados.

Em vista disso, mesmo com resultados favoráveis, como os apresentados pela CNN desenvolvida, ainda há espaço para melhorias, uma vez que essa tarefa enfrenta inúmeros desafios, como a variabilidade nas expressões individuais, a influência de fatores externos (iluminação, ângulo da câmera) e a complexidade de emoções mistas ou ambiguidades. Tudo isso torna o estudo desse assunto extremamente desafiador, necessitando de pesquisas cada vez mais aprofundadas para aprimorar a precisão e a eficácia dos modelos.

REFERÊNCIAS BIBLIOGRÁFICAS

BERCHT, M. Vínculos com a psicologia e aplicações na educação. In: PRADO, O. Z.; FORTIM, I.; COSENTINO, L. (Org.). **Psicologia & informática: produções do III. psicoinfo II. jornada do NPPI**. São Paulo: Conselho Regional de Psicologia de São Paulo: CRP/SP, 2006. p. 106-115.

CHIU, C. Y. *et al.* Multimodal depression detection on instagram considering time interval of posts. **Journal of Intelligent Information Systems**, v. 56, n. 1, p. 25–47, 2020.

CORNEJO, J. Y .R. **Pattern recognition in facial expressions: algorithms and application = Reconhecimento de padrões em expressões faciais: algoritmos e aplicações**. 2020. 1 recurso online (85 p.). Tese (doutorado) - Universidade Estadual de Campinas, Instituto de Computação, Campinas, SP. Disponível em: <https://hdl.handle.net/20.500.12733/1638572>. Acesso em: 30 jun. 2024.

CORTIZ, D.; SANTOS, J. C. F. Computação Afetiva: entre as limitações técnicas e os desafios do colonialismo de dados. **Fronteiras – estudos midiáticos**, v. 24, n. 3, p. 62-71, set./dez. 2022. Unisinos. DOI: 10.4013/fem.2022.242.06. Disponível em: <https://doi.org/10.4013/fem.2022.242.06>. Acesso em: 29 jun. 2024.



MCSTAY, A.; URQUHART, L.. In cars (are we really safest of all?): interior sensing and emotional opacity. **International Review of Law, Computers & Technology**, p. 1-24, 2022.

Disponível

em:

<https://www.researchgate.net/publication/358298799_In_cars_are_we_really_safest_of_all_interior_sensing_and_emotional_opacity>. Acesso em: 15 jun. 2024.

MENÁRGUEZ, A. T. Descubra o professor a quem os alunos não enganam. **El País**, 2016.

Disponível

em:

<https://brasil.elpais.com/brasil/2016/12/08/politica/1481153535_081147.html>. Acesso em: 20 set. 2023.

MIGUEL, F. K. Psicologia das emoções: uma proposta integrativa para compreender a expressão emocional. **Psico - USF**, v. 20, n. 1, p. 153–162, 2015. DOI: 10.1590/1413-82712015200114.

PICARD, R. W. **Affective computing**. Cambridge, MA: M.I.T Media Laboratory Perceptual Computing Section, 1995. (Technical Report, n. 321), p. 1-16.

PRODANOV, C. C.; FREITAS, E. C.. **Metodologia do trabalho científico**: métodos e técnicas da pesquisa e do trabalho acadêmico. 2. ed. Novo Hamburgo: Feevale, 2013. ISBN 978-85-7717-158-3.

SOUSA, F. *et al.* Detecção de Fake News em Língua Portuguesa Combinando Redes Neurais Convolucionais e Algoritmos de Aprendizagem de Máquina. In: SIMPÓSIO BRASILEIRO DE REDES DE COMPUTADORES E SISTEMAS DISTRIBUÍDOS (SBRC), 40. , 2022, Fortaleza. **Anais Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos**. Porto Alegre: Sociedade Brasileira de Computação, 2022. p. 336-348. ISSN 2177-9384. DOI: <https://doi.org/10.5753/sbrc.2022.222325>.

WERLANG, P.; JAQUES, P. A. (2023). Detecção por face de emoções de aprendizagem: abordagem baseada em redes neurais profundas e fluxo de emoções. **Revista Brasileira de Informática na Educação – RBIE**, v. 31,174-204. DOI: 10.5753/rbie.2023.2936.