

Análise de sentimento com rede neural convolucional: uma investigação do fator motivacional da metodologia de aprendizagem criativa

Max Filipe da Costa Braga¹, Wilson Rogério Soares e Silva², Orlando Shigueo Ohashi Junior³, Renato Hidaka Torres¹

¹ Faculdade de Computação – Universidade Federal do Pará (UFPA)
Caixa Postal 15.064 – 91.501-970 – Belém – PA – Brasil

² Campus Avançado Vigia– Instituto Federal do Pará (IFPA)
Vigia – PA – Brasil.

³ Instituto Ciber Espacial – Universidade Federal Rural da Amazônia (UFRA)
Belém – PA – Brasil.

max.braga@icen.ufpa.br, rogerio.soares@ifpa.edu.br
orlando.ohashi@ufra.edu.br, renatohidaka@ufpa.br

Abstract. *This research investigates the use of the Scratch platform in the development and monitoring of creative immersion tests with students. It is believed that interactive proposals such as Scratch provide the student's motivation and contribute to the development of skills and competencies. To verify this hypothesis, we developed three experiments and analyzed the participants' emotions with a convolutional neural network. The results show that happiness and neutrality emotions were predominant. Observing these feelings allows us to conclude that Scratch contributes to the motivational factor of the learning.*

Resumo. *Este artigo investiga a utilização da plataforma Scratch no desenvolvimento e monitoramento de ensaios de imersão criativa com alunos da educação básica. Acredita-se que propostas interativas como o Scratch proporcionam a motivação do aluno e contribuem no desenvolvimento das habilidades e competências. Para verificar essa hipótese, desenvolvemos três roteiros experimentais, no intuito de realizar a análise de sentimento dos participantes. Os sentimentos foram analisados a partir de um de uma rede neural convolucional e os resultados demonstram que o sentimento de felicidade e neutralidade foram predominantes. A observação desses sentimentos permite concluir que o Scratch contribui no fator motivacional do aprendizado.*

1. Introdução

Em 2007, o grupo de pesquisa *Lifelong Kindergarten* do Instituto de Tecnologia de Massachusetts lançou o Scratch [Maloney 2010], uma plataforma de criação digital gratuita e online para crianças. O Scratch é um ambiente que permite que os usuários criem e compartilhem suas próprias histórias, jogos e animações. Desde o seu lançamento, a plataforma já registra mais de 55 milhões de projetos criados e compartilhados por pessoas de todo o mundo. Devido à facilidade de utilização e à alta produtividade para

transformar uma ideia em um produto digital, o Scratch já está consolidado como ferramenta de apoio para o desenvolvimento da aprendizagem criativa.

Segundo [Resnick 2017], a metodologia de aprendizagem criativa tem como objetivo proporcionar um ambiente onde os alunos possam aguçar suas habilidades como pensadores criativos, desenvolvendo, testando, experimentando alternativas, obtendo as opiniões de outras pessoas, e aperfeiçoando suas ideias baseadas em experiências. Nesse sentido, a metodologia de aprendizagem criativa surge como alternativa à metodologia de ensino tradicional na qual o aluno assume a condição passiva de receptor de informações.

Estudos como os de [Daher 2007], apontam que na metodologia tradicional, o estímulo de diferentes habilidades pode ser inibido devido a condição passiva do aluno. Uma vez que as diferentes habilidades não são trabalhadas, como: comunicação, raciocínio lógico, autonomia, trabalhos em equipe; é compreensível que o estudante demonstre desmotivação e até mesmo dificuldade no processo de ensino e aprendizagem. Em certos casos, a dificuldade de aprendizagem pode ser percebida, já que pessoas diferentes aprendem por estímulos diferentes. Logo, o fato de os estudantes passarem grande parte do tempo sentados em suas cadeiras ouvindo as lições de um professor, não possibilita esses diferentes estímulos.

Nesse contexto, com o objetivo de investigar a motivação dos alunos ao utilizarem o ambiente Scratch como instrumento de ensino que corrobora para estimular e aguçar as habilidades, a presente pesquisa analisou os sentimentos dos alunos a partir da aplicação de uma arquitetura de rede neural convolucional (CNN).

Para construir os dados de entrada da CNN, nós elaboramos três roteiros experimentais de construção de jogos educacionais. Os experimentos foram realizados em quatro encontros de forma virtual, utilizando a plataforma Google Meet. Durante os experimentos, com o consentimento dos responsáveis, os encontros foram gravados. A partir da gravação, nós realizamos o pré-processamento das imagens e extraímos as expressões faciais dos participantes durante as etapas de construção e teste dos jogos.

Os resultados mostram que a CNN desenvolvida alcançou uma *accuracy* de 0.82 ao avaliar os sentimentos dos participantes. Sobre a percepção dos sentimentos durante os roteiros experimentais, o sentimento neutro e de felicidade foram predominantes. Esse comportamento demonstra que os alunos ficaram, na maior parte do tempo, concentrados ou felizes por estarem aprendendo a partir da metodologia de aprendizagem criativa. Assim, os resultados da classificação da CNN nos permitem concluir que o ambiente Scratch contribui para potencializar o fator motivacional dos alunos e, consequentemente, possibilita estimular e aguçar as diferentes habilidades.

As próximas seções desse artigo estão divididas da seguinte forma: na seção 2 abordaremos sobre os trabalhos relacionados, na seção 3 explanaremos como os roteiros experimentais foram construídos e como a coleta de dados foi realizada; na seção 4 será descrita a construção e a avaliação da CNN desenvolvida para analisar o sentimento dos participantes; na seção 5 analisaremos os sentimentos dos alunos, bem como avaliaremos o desempenho da CNN; por fim, na seção 6 apresentaremos as considerações finais desse trabalho.

2. Trabalhos Relacionados.

A fim de investigar os trabalhos que desenvolveram roteiros experimentais para analisar o sentimento no contexto educacional, [Bobó et al. 2019] realizou um mapeamento sistemático da literatura. No referido trabalho, o autor analisou as técnicas, métodos, arquiteturas e algoritmos de análise de sentimento com o objetivo de identificar quais sentimentos têm sido considerados e a origem dos textos analisados do ponto de vista do estudante. O diferencial dos trabalhos filtrados por [Bobó et al. 2019] em relação à presente pesquisa, está na fonte de dados considerada para a investigação dos sentimentos. Enquanto os trabalhos filtrados analisaram os sentimentos a partir dos textos produzidos pelos alunos, na presente pesquisa, tal análise foi realizada a partir da observação de expressões faciais dos participantes capturadas durante os roteiros experimentais. A abordagem de análise de sentimentos por expressões faciais é interessante, uma vez que possibilita sua aplicação em diferentes contextos. Por exemplo, para analisar a motivação dos alunos ao utilizar a ferramenta Scratch, conforme proposto neste trabalho.

Trabalhos como os de [Zaletelj e Košir 2017] e [Dinesh e Bijlani 2016] desenvolveram pesquisas na mesma linha de análise de sentimentos dos estudantes a partir da observação de expressões faciais. Na ocasião, [Zaletelj e Košir 2017] utilizou o sensor *Kinect One* para capturar propriedades faciais e corporais dos alunos durante uma aula tradicional. A partir dos dados coletados, os autores desenvolveram modelos de aprendizado de máquina para realizar a predição da atenção dos participantes. Nessa mesma linha, a pesquisa desenvolvida por [Dinesh e Bijlani 2016] capturou a imagem de alunos durante a condução de aulas online no formato tradicional e classificou a atenção dos alunos. Ao comparar as referidas pesquisas com a proposta desse trabalho, pode-se perceber a diferença do contexto experimental. Enquanto as pesquisas de [Zaletelj e Košir 2017] e [Dinesh e Bijlani 2016] tiveram como objetivo investigar a atenção dos alunos que assistiam aulas tradicionais, na presente pesquisa o objetivo implica a investigação da motivação do aluno no contexto da aprendizagem criativa.

Em relação à técnica utilizada para realização da predição dos sentimentos, assim como na presente proposta, trabalhos como os de [Franco et al. 2019] e [Grando 2020] também desenvolveram modelos de aprendizado de máquina fundamentados no algoritmo de rede neural convolucional. [Franco et al. 2019] desenvolveu diferentes CNN's para construir a ferramenta UXmood que pode ser utilizada para analisar o sentimento de experiências de usuários em diferentes contextos, a partir de fontes de dados heterogêneas tais como: áudio, vídeo, texto e rastreamento ocular. Já [Grando 2020], desenvolveu um modelo de CNN para avaliar os sentimentos de estudantes no contexto de sala de aula inteligente. Apesar de ser um contexto de aplicação diferente do proposto na presente pesquisa, por utilizarem técnicas semelhantes à da presente proposta, foi admitida a possibilidade de realizar um estudo comparativo de performance preditiva. Entretanto, ao entrar em contato com os autores dos trabalhos de [Franco et al. 2019] e [Grando 2020], eles comunicaram que as ferramentas não estavam disponíveis.

Ao comparar a presente proposta com os trabalhos correlatos, pode-se perceber que o maior diferencial está no contexto da aplicação. Enquanto os trabalhos filtrados pela revisão sistemática conduzida por [Bobó et al. 2019], bem como as demais propostas mencionadas tiveram como objetivo avaliar o sentimento dos alunos no contexto de sala de aula tradicional, esse trabalho tem como objetivo investigar e analisar o senti-

mento dos alunos no contexto da aprendizagem criativa, a partir da utilização da ferramenta Scratch.

3. Roteiros Experimentais e Coleta de Dados

A fim de realizar a coleta das expressões faciais dos alunos, nós construímos três roteiros experimentais. Cada roteiro consiste em um jogo educacional desenvolvido na plataforma Scratch (ver Figura 1). Para que os alunos pudessem utilizar os jogos e criá-los, foi organizado no *Google Drive* [Braga-A 2021] um conjunto de pastas com todos os materiais necessários para execução dos roteiros. Ademais, para cada jogo, também foi criada uma *playlist* [Braga-B 2021] com um tutorial em vídeo, mostrando todas as etapas de elaboração dos *games*.



Figura 1: Nessa figura apresentamos a tela inicial dos três jogos que foram construídos pelos participantes durante os roteiros experimentais. Os jogos podem ser acessados a partir de link <https://scratch.mit.edu/search/projects?q=maxbraga>. Fonte: O autor.

Devido a pandemia da COVID-19, a execução dos roteiros experimentais foi realizada através da plataforma *Google Meet*. No total, foram realizados 4 encontros síncronos entre os meses de fevereiro e março. Cada encontro durou entre duas horas e duas horas e meia. Esses momentos foram divididos em duas partes: I – momento de conhecer e jogar os jogos educativos; II – momento de construção dos jogos, onde os alunos foram desafiados a montarem os jogos com os materiais de apoio.

O primeiro encontro foi utilizado para apresentar os objetivos do experimento, para pedir o consentimento de gravação e para apresentar o ambiente Scratch. Os outros três encontros foram utilizados para a construção dos jogos propostos. Nesses encontros, os participantes primeiramente utilizavam os jogos já construídos para verificar a jogabilidade e se divertirem. Em seguida, estando motivados, iriam aprender a construir os jogos que estavam jogando previamente.

Inicialmente, estava prevista a participação de cinco estudantes para a realização dos experimentos, três de escolas públicas da periferia de Belém e dois de escolas particulares, com idades entre 10 e 17 anos. Entretanto, por motivos pessoais e falta de recursos para participar do projeto, houve a desistência dos três participantes das escolas públicas. Assim, sem prejuízo, a condução dos experimentos seguiu com apenas dois participantes. As imagens dos participantes foram gravadas durante as fases de diversão e construção. No total, foram realizadas mais de 05 horas de gravação. A partir da gravação, nós realizamos a extração e o pré-processamento de frames, com o objetivo de

construir a base de dados para a análise dos sentimentos. A base de dados foi formada por 120 imagens dos participantes. Para cada imagem, nós realizamos a etapa de pré-processamento que implicou no recorte e padronização dos tamanhos das imagens.

É importante ressaltar que o conjunto de imagens que nós extraímos foi utilizado exclusivamente para avaliar o sentimento dos alunos a partir de uma rede neural convolucional. Essas imagens não foram utilizadas na fase de treinamento e validação da CNN desenvolvida. Contudo, por sabermos o sentimento esperado de cada imagem da nossa base de dados, utilizamos esse conjunto de dados para avaliar o desempenho de classificação realizada pela rede. Sobre a arquitetura de CNN a ser testada, a seção 4 detalha como ela foi construída.

4. Arquitetura CNN para análise de sentimentos

A rede neural convolucional é um tipo de aprendizado de máquina profundo que tem demonstrado eficiência em problemas que requerem a detecção e classificação de objetos a partir de imagens. Arquiteturas como LeNet-5, AlexNet, ZFNet, VGGNet, GoogLeNet e ResNet mostram a evolução das CNNs e uma tendência para arquiteturas cada vez mais profundas. Entretanto, dependendo das características do domínio de entrada, há a necessidade da construção de uma arquitetura específica que consiga generalizar o problema investigado. Por exemplo, para analisar os sentimentos dos alunos, a arquitetura ResNet pode ser ineficiente ou até mesmo muito sofisticada. Considerando a hipótese de ser sofisticada, ao utilizar a arquitetura ResNet, estaríamos consumindo muitos recursos computacionais desnecessariamente, uma vez que uma arquitetura mais simples também poderia resolver o problema.

Nesse contexto, para classificar o sentimento dos alunos durante os roteiros experimentais, nós construímos uma arquitetura de CNN fundamentada no trabalho de [Mohammad 2019]. Nessa CNN, o dado de entrada pode ser classificado em 6 sentimentos, quais sejam: felicidade, neutro, tristeza, raiva, surpresa e assustado. Para realizar a classificação, a arquitetura construída é composta por 9 camadas, conforme ilustrado na Figura 2.

As camadas de C1 a C6 são camadas convolucionais que tem como objetivo filtrar e extrair as características dos dados de entrada. Nessas camadas, nós utilizamos 32 filtros convolucionais de dimensão 3x3 e a função de ativação *ReLU*. Nas camadas pares, nós também utilizamos a função *MaxPooling* de dimensão 2x2. Segundo [Goodfellow et al. 2016], as funções de *pooling* têm como objetivo tornar o mapeamento de características invariantes, mesmo que existam variações nos valores de entrada. Além disso, a fim de reduzir a possibilidade de *overfitting*, ao final de cada camada, nós aplicamos a normalização e o *dropout* de 0.5 sobre os valores de saída.

As camadas C7 e C8 correspondem à duas camadas totalmente conectadas de 64 neurônios cada uma. Essas duas camadas foram criadas com o objetivo de permitir que a rede explore todas as características extraídas nas camadas convolucionais e crie regras para classificar os sentimentos dos alunos. Por fim, a camada C9 corresponde a camada de saída da rede. Por ser um problema de 6 classes, nós utilizamos a função não linear *softmax*.

Para treinar a CNN, nós utilizamos a base de dados FER-2013 [Goodfellow et al, 2015] que é uma base de dados formada por 35.685 imagens em tons de cinza de 48x48 pixels. As imagens apresentam expressões faciais que correspondem as classes C0: felicidade,

C1: neutro, C2: tristeza, C3: raiva, C4: surpresa e C5: assustado. Por ser uma base com expressivo volume de dados, nos separamos 70% dos dados para realizar o treinamento da rede e os outros 30% para validação. O teste do modelo treinado foi realizado com as imagens de expressões faciais coletadas nos nossos roteiros experimentais realizados com os alunos.

Na Figura 3, podemos observar o desempenho da CNN para os conjuntos de treinamento e validação. A proximidade das curvas de treinamento e validação, tanto para a *accuracy* quanto para a *loss*, indica que a CNN não apresentou *overfitting*. A estabilização do desempenho do modelo a partir da época 50, indica que aumentar o número de épocas não agregaria maior ganho de performance preditiva. Sendo assim, considerando a complexidade da tarefa de predição, entendemos que o desempenho da arquitetura projetada é aceitável e pode ser utilizada para inferir os sentimentos dos alunos quando submetidos a experimentos de aprendizagem criativa utilizando o ambiente Scratch.

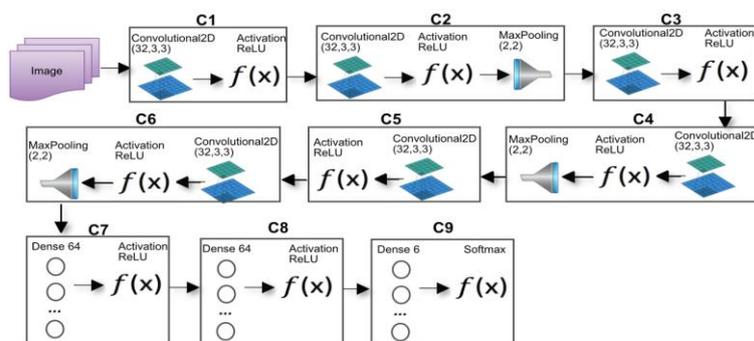


Figura 2: Arquitetura CNN desenvolvida para realizar a predição dos sentimentos durante a construção dos jogos. Classes de predição: {neutro, felicidade, tristeza, raiva, surpresa, assustado}. Fonte: o autor.

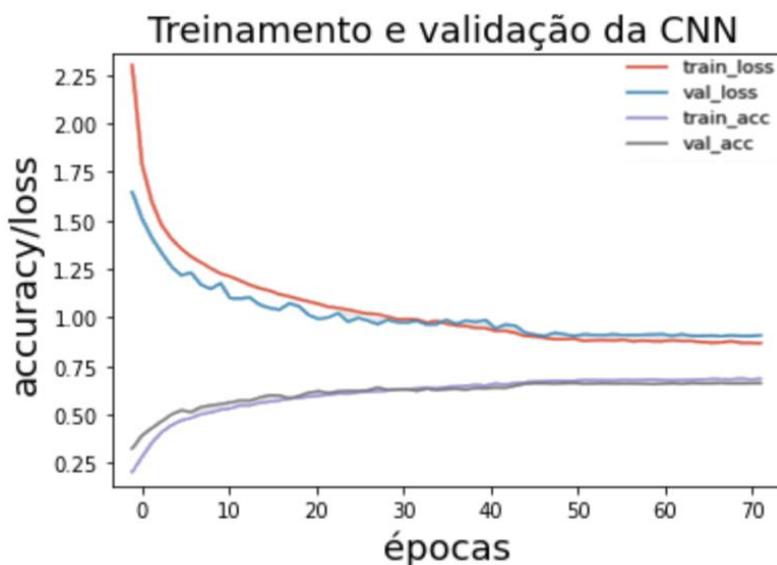


Figura 3: Curvas de desempenho do treinamento e avaliação, levando em consideração as métricas *accuracy* e *loss*. A proximidade das curvas demonstra a capacidade de generalização da CNN e a *accuracy* de 0.75 é aceitável, dada a complexidade do problema. Fonte: o autor.

5. Análise de sentimentos

Conforme explanado na seção 3, nós construímos uma base de dados com 120 imagens a partir da extração e pré-processamento de frames procedentes das gravações realizadas durante os experimentos. Considerando que os roteiros experimentais foram divididos nos momentos de diversão e construção, nós coletamos 30 imagens de cada participante durante esses dois momentos. Após a coleta, nós avaliamos e rotulamos as imagens com o sentimento esperado. Na Figura 4, podemos observar a avaliação dos sentimentos dos dois participantes. A área em azul do aluno 1 e a área verde do aluno 2, correspondem aos sentimentos rotulados a partir da observação dos 60 frames de cada um dos participantes. A área vermelha dos dois gráficos corresponde a predição dos sentimentos realizada pela rede neural convolucional.

Ao analisar o sentimento dos participantes, podemos observar que o sentimento neutro e felicidade foi predominante para os dois participantes. Além disso, também é possível perceber que a predição realizada pela CNN foi próxima dos valores esperados. No contexto do roteiro experimental dessa pesquisa, o sentimento neutro pode ser correlacionado com os momentos de concentração dos alunos. Para conseguir construir os jogos, é esperado que o aluno se concentre. Por esse motivo, como pode ser observado na Figura 4, o pico das formas geométricas vermelha, demonstra que a classe neutra foi a predição de maior frequência realizada pela CNN.

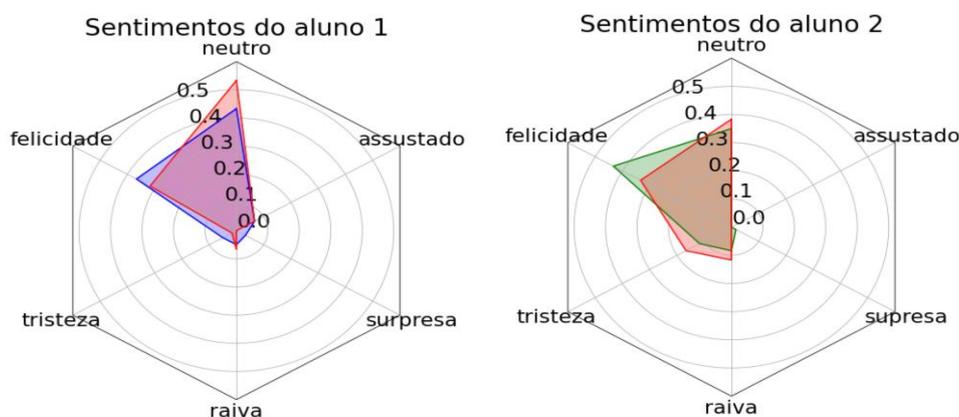


Figura 4: Análise de dos sentimentos dos participantes durante os ensaios experimentais. A área vermelha corresponde ao sentimento que a CNN previu a partir das 120 imagens da base de teste. A predominância dos sentimentos neutro e felicidade demonstra que os participantes ficaram concentrados e felizes durante os ensaios. Fonte: o autor.

Em relação ao sentimento de felicidade, esse está diretamente relacionado com o fator motivacional do aluno. Nesse caso, ao perceber o sentimento de felicidade, podemos inferir que a utilização do ambiente Scratch de fato contribui para potencializar o fator motivacional, na perspectiva da metodologia de aprendizagem criativa.

Além de analisar o perfil dos sentimentos dos participantes, nós também utilizamos as 120 imagens para testar o desempenho da CNN. Conforme observado na Figu-

ra 3, para os dados de treinamento e validação, a CNN apresentou uma *accuracy* próxima de 0.75. Apesar de não ser tão próximo de 1, entendemos que, devido a complexidade da tarefa, o desempenho foi satisfatório. Com os dados de teste, como os sentimentos neutro e felicidade foram predominantes, espera-se que esse desbalanceamento diminua a complexidade de predição multiclases. Nesse caso, o comportamento esperado é que a rede neural convolucional apresente melhor desempenho para o conjunto de dados de teste.

Para avaliar o desempenho da rede, nós utilizamos as métricas *accuracy*, *precision*, *recall* e *F1-score*. A métrica *accuracy* tem como objetivo avaliar o desempenho global do classificador. Já as métricas *precision* e *recall* avaliam o desempenho do classificador para cada classe do problema, levando em consideração a taxa de falsos positivos e falsos negativos, respectivamente. Por fim, a métrica *F1-score* corresponde a média harmônica das métricas *precision* e *recall* e tem como objetivo verificar o balanceamento dos falsos positivos e falsos negativos classificados pelo modelo. A Figura 5 demonstra como cada métrica é computada.

Para computar as métricas em função dos dados de teste, nós construímos a matriz de confusão apresentada na Figura 6. A diagonal principal corresponde aos valores corretamente classificados pela CNN, ou seja, são os verdadeiros positivos (VP) e verdadeiros negativos (VN) de cada classe. Os valores de uma linha, exceto a célula da diagonal principal, correspondem aos falsos negativos (FN) de uma classe. Já os valores das colunas, exceto a célula da diagonal principal, correspondem aos falsos positivos (FP) de uma classe.

$$accuracy = \frac{VP + VN}{VP + VN + FP + FN} \quad precision = \frac{VP}{VP + FP}$$

$$recall = \frac{VP}{VP + FN} \quad F1_score = \frac{2 \times precision \times recall}{precision + recall}$$

Figura 5: Métricas utilizadas para avaliar a CNN a partir dos dados coletados durante os experimentos. Fonte: o autor.

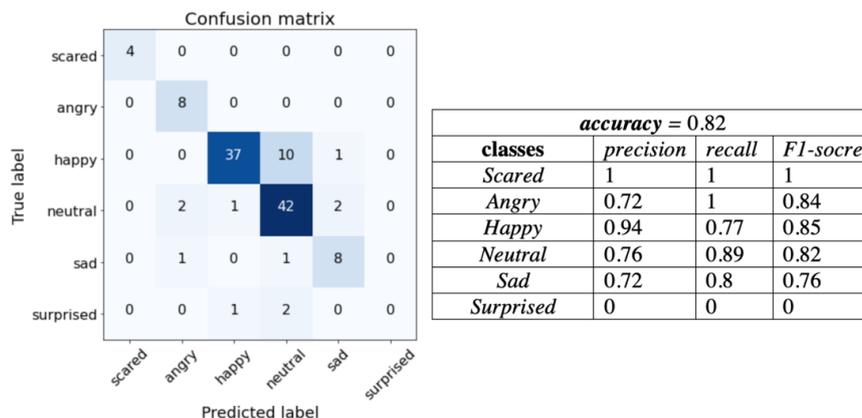


Figura 6: Matriz de confusão gerada a partir da predição das 120 imagens coletadas durante os experimentos. A tabela ao lado corresponde às métricas calculadas a partir dos valores da matriz. Fonte: o autor.

Na Figura 6, também temos os valores calculados de cada métrica. Ao analisar a *accuracy* de 0.82, podemos perceber que esta foi significativamente melhor do que a *accuracy* de 0.75 obtida durante a etapa de treinamento e validação da CNN. Esse comportamento é justificado devido a representatividade de classes no conjunto de teste. Como os alunos expressaram na maior parte do tempo os sentimentos neutro e feliz, as demais classes não tiveram representatividade e, por esse motivo, o classificador minimizou o seu erro.

Ao analisar os valores das métricas *precision*, *recall* e *F1-score*, percebemos que harmonicamente todas as métricas estão em conformidade com a *accuracy*. A maior diferença acontece na precisão e revocação do sentimento de felicidade. Nesse caso, podemos observar que a quantidade de falsos negativos foi consideravelmente maior do que a quantidade de falso positivos. Em termo práticos, isso significa que algumas amostras que veriam a ser classificadas com o sentimento de felicidade foram erroneamente classificadas. Contudo, ainda assim o resultado é satisfatório e comprova que a arquitetura CNN projetada pode ser utilizada para avaliar o sentimento dos alunos, quando submetidos a roteiros experimentais de aprendizagem criativa.

6. Considerações finais

Esse trabalho teve como objetivo investigar a motivação dos alunos ao utilizarem o ambiente Scratch como instrumento de ensino que corrobora para estimular e aguçar as habilidades. Para isso, nós desenvolvemos uma arquitetura de rede neural convolucional, a fim de prever os sentimentos dos participantes. Os resultados obtidos demonstram que a arquitetura desenvolvida possui confiabilidade na predição e que os sentimentos predominantemente observados foram os de felicidade e neutralidade. No contexto dessa pesquisa, entendemos que o sentimento neutro refletiu a concentração do aluno enquanto estava realizando as atividades de construção dos jogos. Já o sentimento de felicidade, está diretamente relacionado ao fator motivacional, objeto de investigação dessa pesquisa. Uma vez observado a alta frequência da predição desses dois sentimentos, concluímos que a utilização do ambiente Scratch pode contribuir para aguçar as diferentes habilidades dos alunos e, conseqüentemente, ajudar no processo de aprendizagem de forma proativa. Como trabalhos futuros, pretendemos realizar outros ensaios experimentais com maior quantidade de participantes e comparar o sentimento quando submetidos às atividades tradicionais como, por exemplo, resolução de lista de exercício.

Referências

- Bobó, M.; Campos, F.; Ströele, V.; Braga, R.; David, J. M. N. (2019). Análise de Sentimentos na Educação: Um Mapeamento Sistemático da Literatura. In: Anais do XXX SBIE – VIII CBIE. Brasília – DF, Brasil.
- Braga-A, Max. (2021). Materiais para a construção dos Jogos Educativos na Plataforma Scratch. <https://bit.ly/ArquivosJogosEducativos>. Abril.
- Braga-B, Max. (2021). Playlist dos jogos Educativos. <http://bit.ly/PlaylistDosJogos>. Abril.

- Dinesh, D. e Bijlani, K. (2016). Student analytics for productive teaching/learning. In: 2016 International Conference on Information Science (ICIS). [S.l.: s.n.]. p. 97–102.
- Franco, Roberto Y. da S. (2019). X mood: A tool to investigate the user experience (UX) based on multimodal Sentiment analysis and information visualization (InfoVis). In: International Conference Information Visualization (IV) 23rd. Qualis: B1.
- Goodfellow, I., Bengio, Y., e Courville, A. (2016). Deep Learning. The MIT Press.
- Goodfellow, I., Erhan, D., Carrier, P., Courville, A., Mirza, M., Hamner, B., Cukierski, W., Tang, Y., Thaler, D., Lee, D., Zhou, Y., Ramaiah, C., Feng, F., Li, R., Wang, X., Athanasakis, D., Shave-Taylor, J., Milakov, M., Park, J., Ionescu, R., Popescu, M., Grozea, C., Bergstra, J., Xie, J., Romaszko, L., Xu, B., Chuang, Z., e Bengio, Y. (2015) Challenges in representation learning: A report on three machine learning contests. *Neural Networks*, 64:59--63. Special Issue on "Deep Learning of Representations".
- Grando, Aldoir. (2020). Análise facial de emoções utilizando redes neurais no contexto de uma sala de aula inteligente. Caxias do Sul – RS, Brasil.
- Daher, Alessandra Ferreira Beker. (2007). Aluno e professor: protagonistas do processo de aprendizagem.
- Maloney, J., Resnick, M., Rusk, N., Silverman, B., e Eastmond, E. (2010). The Scratch programming language and environment. *ACM Transactions on Computing Education*, 10(4):16:1–16:15.
- Mohammad, Chaudhari Amol. (2019). Emotion Recognition Using Keras. Medium. <https://medium.com/@ee18m003/emotion-recognition-using-keras-ad7881e2c3c6>. Outubro.
- Resnick, M. (2017). *Lifelong Kindergarten: Cultivating Creativity through Projects, Passions, Peers, and Play*. MIT Press.
- Zaletelj, J.; Košir, A. (2017). Predicting students' attention in the classroom from kinect facial and body features. *EURASIP Journal on Image and Video Processing*, Springer Nature, v. 2017, n. 1, dez.