

ANAIS

SIMPÓSIO DE
LICENCIATURAS EM
CIÊNCIAS EXATAS E
EM COMPUTAÇÃO

VI SLEC



UNIVERSIDADE FEDERAL DO PARANÁ

Licenciatura em Ciências Exatas - Jandaia do Sul

Licenciatura em Ciências Exatas - Palotina

Licenciatura em Ciências Exatas - Pontal do Paraná

Licenciatura em Computação - Jandaia do Sul

Licenciatura em Computação - Palotina

VI SIMPÓSIO DE LICENCIATURAS EM CIÊNCIAS EXATAS E EM COMPUTAÇÃO

Jandaia do Sul

2023

Universidade Federal do Paraná. Sistemas de Bibliotecas.
Biblioteca UFPR Palotina.

S612 Simpósio de licenciaturas em Ciências Exatas e em
 Computação (6. : 2023 set. 21-23: Jandaia do Sul, PR).
 Anais do VI Simpósio de licenciaturas em Ciências Exatas e
em Computação / organizado por Maytê Gouvêa Coletto
Bezerra ... [et. al.]. – Jandaia do Sul: UFPR, 2023.
 [Recurso eletrônico]

ISSN: 2594-9837

1. Educação a Distância. 2. Formação de Professores.
3. Tecnologias digitais. 4. Educação Básica. I. Bezerra, Maytê
Gouvêa Coletto. II. Philippsen, Gisele Strieder. III. Valério, Marcelo.
IV. Silva, Aroldo Nascimento. V. Marcolino, Anderson da Silva.
VI. Universidade Federal do Paraná. VII. Título.

CDU: 004(063)

Ficha Catalográfica elaborada por: Aparecida Pereira dos Santos CRB9/1653

UFPR

Gestão 2021-2024

Reitor

Prof. Dr. Ricardo Marcelo Fonseca

Vice-Reitora

Prof^a. Dr^a. Graciela Ines Bolzón de Muniz

Pró-Reitor de Administração

Prof. Dr. Eduardo Salamuni

Pró-Reitora de Assuntos Estudantis

Prof^a. Dr^a. Maria Rita de Assis Cesar

Pró-Reitora de Extensão e Cultura

Prof. Dr. Rodrigo Arantes Reis

Pró-Reitora de Gestão de Pessoas

Douglas Ortiz Hamermuller

Pró-Reitor de Graduação e Educação Profissional

Prof. Dr. Julio Gomes

Pró-Reitor de Pesquisa e Pós-Graduação

Prof. Dr. Francisco de Assis Mendonça

Pró-Reitora de Planejamento, Orçamento e Finanças

Prof. Dr. Fernando Marinho Mezzadri

Direção do Campus Jandaia do Sul

Prof. Dr. José Eduardo Padilha de Sousa

Direção do Campus Pontal do Paraná

Prof. Dr. José Guilherme Bersano Filho

Direção do Setor Palotina

Prof. Dr. Wilson de Aguiar Beninca

Direção de Desenvolvimento e Integração dos Campi – INTEGRA UFPR

Prof. Dr. Renato Bochicchio

ORGANIZAÇÃO

Comissão Organizadora

Profª. Drª. Maytê Gouvêa Coletto Bezerra

Profª. Drª. Gisele Strieder Philippsen

Prof. Dr. Marcelo Valério

Prof. Dr. Aroldo Nascimento Silva

Prof. Dr. Anderson da Silva Marcolino

Comissão Científica

Coordenação Geral da Comissão Científica

Prof. Dr. Anderson da Silva Marcolino (UFPR Palotina)

Informática Educativa e Educação em Computação

Coordenação de área: Prof. Dr. Anderson da Silva Marcolino (UFPR Palotina)

Profª. Mª. Paola Cavalheiro Ponciano (UFPR Palotina)

Profª. Drª. Selma dos Santos Rosa (UFPR Litoral)

Prof. Dr. Rogério Ferreira da Silva (UFPR Jandaia)

Prof. Dr. Marcelo Franco de Oliveira (UFPR Jandaia)

Prof. Dr. Hélio Henrique L. C. Monte Alto (UFPR Jandaia)

Educação Matemática

Coordenação de área: Prof. Dr. Wellington Piveta Oliveira (UNESPAR Paranavaí & Unicesumar)

Profª. Drª. Bárbara Cândido Braz (UFPR Jandaia)

Profª. Drª. Michele Carvalho de Barros (UTFPR/ Campus de Campo Mourão)

Profª. Drª. Flavia Pollyany Teodoro (UNESPAR/ Campus de Campo Mourão)

Profª. Drª. Daniela Barbieri Vidotti (UNESPAR/ Campus de Paranavaí)

Profª. Mª. Ana Caroline Zampirolli (Doutoranda PCM/UEM)

Profª. Mrª. Camila Bonini Araujo Cassoli (Doutoranda PCM/UEM)

Ensino de Química

Coordenação de área: Prof. Dr. Aroldo Nascimento Silva (UFPR Jandaia)

Prof. Dr. Jaime da Costa Cedran (UEM)

Prof. Me. Lucas Muller Ribeiro Vianna (SEDUC/SP)

Prof. Me. Jailson Rodrigo Pacheco (Doutorando PPGECEM/UFPR)

Profª. Drª. Luana Pires Vida Leal (SEED/PR)

Profª. Drª. Luciane Fernandes de Goes (USP/SP)

Ensino de Física

Coordenação de área: Prof^a. Dr^a. Gisele Strieder Philippsen (UFPR Jandaia)

Prof^a. Dr^a. Hercília Alves Pereira de Cavalho (UFPR Jandaia)

Prof. Dr. William Junior do Nascimento (UFPR Jandaia)

Prof. Me. Guilherme Henrique Correia Domingues (Doutorando PECEM/UEL)

Prof. Me. Leonardo Deosti (Doutorando PCM/UEM)

Prof. Dr. Valdir Rosa (UFPR Litoral)

Prof^a. Dr^a. Camila Tonezer (UFPR Palotina)

Prof. Dr. Arthur Bergold (UFPR Palotina)

Fundamentos da Educação e articulações interdisciplinares

Coordenação de área: Prof a. Dra. Maytê Gouvêa Coletto Bezerra

Prof. Dr. Marcelo Valério

Prof^a. Dr^a. Roberta Chiesa Bartelmebs (UFPR Palotina)

Equipes de Organização

Caderno de Atas (Anais do evento) | Organização e Editoração

Prof. Me. Carlos Eurico Galvão Rosa (UFPR Jandaia)

Prof. Dr. Anderson da Silva Marcolino (UFPR Palotina)

Coordenação da Monitoria

Graduanda Ana Carolina Guilhen

Graduando Clelvin Cristian dos Santos

Atividades Artísticas e Culturais

Prof^a. Dr^a. Maytê Gouvêa Coletto Bezerra

Divulgação e Comunicação

Graduanda Valquíria Santos Pedroso da Silva (Bolsista de Comunicação Institucional do Campus Avançado Jandaia do Sul)

Suporte técnico

Prof. Dr. Anderson da Silva Marcolino

Graduando Alan Cesar de Oliveira Mathias

Capa

Prof. Dr. Anderson da Silva Marcolino

Ficha Catalográfica

APOIOS

Colegiado do Curso de Licenciatura em Ciências Exatas – Jandaia do Sul

Colegiado do Curso de Licenciatura em Computação – Jandaia do Sul

Núcleo de Tecnologias Educacionais – NTE-Teia – UFPR Jandaia do Sul

Diretoria de Desenvolvimento e Integração dos Campi do Interior da UFPR -

INTEGRA



SUMÁRIO

ORGANIZAÇÃO.....	5
SUMÁRIO.....	8
APRESENTAÇÃO.....	8
PROGRAMAÇÃO.....	10
RECONHECIMENTO DE EXPRESSÕES FACIAIS COM CNN E SEU POTENCIAL NO APOIO AO ENSINO E APRENDIZAGEM.....	13
QUEBRANDO A TENSÃO DE APRENDER QUÍMICA COM ATIVIDADES FEITAS FORA DA SALA DE AULA: UM RELATO SOBRE O “CIÊNCIA NO INTERVALO”	24

APRESENTAÇÃO

O Simpósio de Licenciaturas em Ciências Exatas e em Computação – SLEC é um evento que vem se consolidando no âmbito das Licenciaturas de Ciências e Computação (Campus Avançado de Jandaia do Sul, o Centro de Estudo do Mar e o Setor Palotina) e em 2023, em sua 6ª edição, foi realizado no campus avançado de Jandaia do Sul.

Foram três dias repletos de conhecimento e compartilhamento de experiências, por meio de palestras, mesas-redondas, apresentações orais e de pôsteres, e minicursos.

No que se refere aos trabalhos submetidos, notou-se e eximia heterogeneidade dos diversos docentes, discentes, pesquisadores e pesquisadores nos 14 trabalhos aprovados.

Os trabalhos foram divididos em três categorias. Dois foram submetidos como apresentação de material, seis como relato de experiência, e seis como resultados de pesquisa. Por sua vez, os trabalhos divididos nas três categorias estavam alocados a cinco áreas temáticas. Quatro na área temática de Articulações Interdisciplinares e outras práticas educativas, um da área temática Educação Matemática, três de Ensino de Física, três de Ensino de Química, e quatro na área temática de Informática na Educação e Educação em Computação.

Destarte, quanto à publicização, dois trabalhos são apresentados neste caderno de anais e 12, na Revista Arquivos do Mudi, v. 27 n. ESPECIAL3 (2023): VI Simpósio de Licenciaturas em Ciências Exatas e em Computação – SLEC (DOI: <https://doi.org/10.4025/arqmudi.v27iESPECIAL>).

Nossos agradecimentos a todos que contribuíram para a realização do SLEC 2023 e, especialmente, aos autores dos trabalhos.

Comissão Organizadora SLEC 2022.

PROGRAMAÇÃO

Data	Local	Atividades	
Quinta (21/09/23)	Auditório Municipal	<p>19:00h – Abertura do evento</p> <p>19:30h – Palestra de Abertura: “Da ponte pra cá: divulgando a ciência com estratégias que a quebrada me ensinou” – Lucas Andrade (Lukera, do Alô. Ciência?) – Biólogo, Ilustrador, Podcaster, Especialista em Comunicação Pública da Ciências (Amerek – UFMG) – @alociencia @lukeraandrade</p> <p>20:30h – Espaço para perguntas</p> <p>21:00h – Apresentação cultural – Escola de Dança Brisé Volé</p> <p>21:40h – Coffee break</p>	
Sexta (22/09/2023)	Campus UFPR	<p>Minicursos (3h) 08:30 às 10:00h e 10:30 às 12:00 h</p> <p>Propostas pedagógicas e instrumentos avaliativos no Ensino de Física (Sala C110) Prof. Dr. Michel Corci Batista – UTFPR</p>	<p>Oficinas (3h) 08:30 às 10:00h e 10:30 às 12:00 h</p> <p>Como organizar seu perfil acadêmico? Lattes, Orcid, Google Scholar e outros (Sala C117) Prof. Dr. Guilherme Sippel Machado UFPR campus Pontal do Paraná – Centro de Estudos do Mar</p> <p>Ciência de Dados & Educação: uma oficina de introdução à Data Science com dados do MEC (Sala C106 – Laboratório de Informática) Prof. Rogério Ferreira da Silva (UFPR – Campus Avançado Jandaia do Sul)</p> <p>Introdução à Robótica com Arduino (Sala C103) Prof. Marcelo Franco de Oliveira (UFPR – Campus Avançado Jandaia do Sul)</p>

Data	Local	Atividades
		<p>A Ciência da Investigação Criminal (Sala B201 – Sala Paulo Freire) Profa. Dra. Mara Fernanda Parisoto UFPR Palotina</p> <p>Línguas naturais e inteligência artificial: discutindo os limites do ciberespaço (Sala B307 – sala Hands On) Thayse Letícia Ferreira (UNESPAR Apucarana) Julio William Curvelo Barbosa (UNESPAR Paranaguá)</p>
Sexta (22/09/2023)	Auditório Municipal	<p>14:00h às 16:00h – Mesa redonda “Ciência é espaço, tempo e lugar de mulher” Profa. Dra. Rozenilda Luz Oliveira de Matos – UNESPAR Profa. Dra. Rita de Cássia dos Anjos – UFPR Palotina Profa. Dra. Juliana Verga Shirabayashi – UFPR Jandaia</p> <p>16:00h às 18:00h – Coffee e sessão de pôsteres</p>
	Praça do Café	<p>19:00h às 20:30h – Espaço Arte & Ciência Super tenda com Produtos educacionais, Roda de conversa com egressos, Projetos de Pesquisa e Extensão.</p> <p>19:00h às 20:30h – Planetário Atração aberta à comunidade!</p>
Sábado (23/09/2023)	Auditório Municipal	<p>8:30h às 10:00h – Mesa redonda “Tudo novo, de novo: o futuro do Ensino Médio no Brasil”. Prof. Dra. Mônica Ribeiro – UFPR (participação online) Licenciado Gustavo Tresco – Assessor Parlamentar para assuntos de Educação Básica e Superior. Professora Vanda Bandeira Santana (Secretária Educacional – APP/Sindicato) Prof. Dra. Tania Regina Corredato Periotto (Centro de Integração Empresa-Escola CIEE Maringá)</p> <p>10:00h às 10:30h – Coffe break</p>

Data	Local	Atividades
		10:30h às 11:45h – Apresentação dos trabalhos-destaque, selecionados para Comunicação Oral. 11:45h – Encerramento do evento



RECONHECIMENTO DE EXPRESSÕES FACIAIS COM CNN E SEU POTENCIAL NO APOIO AO ENSINO E APRENDIZAGEM

Jorge Luiz dos Santos Canuto

Licenciado

Universidade Estadual de Maringá

pg404818@uem.br

Rodrigo Clemente Thom de Souza

Doutor

Universidade Federal do Paraná

thom@ufpr.br

RESUMO

O reconhecimento das emoções baseado em expressões faciais pode ser realizado por meio de algoritmos conhecidos como *Convolutional Neural Network (CNN)*. As *CNNs* são modelos de aprendizagem profunda aplicáveis a diversos problemas de visão computacional, dentre eles, o Reconhecimento de Expressões Faciais. Recentemente, uma técnica de aprendizagem de máquina conhecida como *Transfer Learning (TL)*, têm prometido ajudar no desempenho dos modelos de *CNN* em diversas tarefas. Diante disso, o presente trabalho visa avaliar o desempenho de modelos de *CNN* com *TL* aplicado ao problema de reconhecimento de expressões faciais. Como melhor resultado, obtivemos o desempenho de 65% de acurácia com o modelo VGG16 com *TL*.

PALAVRAS-CHAVE: Reconhecimento de Expressões Faciais. *Convolutional Neural Network (CNN)*. *Transfer Learning (TL)*.



1. INTRODUÇÃO

Nos últimos anos, vimos um crescimento exponencial de modelos de aprendizagem baseados na internet (e-Learning). A transição para as tecnologias online na educação oferece oportunidades para usar novas metodologias de aprendizagem e métodos de ensino mais eficazes (BAYLARI; MONTAZER, 2009). Além disso, a substituição dos sistemas tradicionais de educação pelo e-Learning oferece vários benefícios, como melhoria no desempenho e redução de custos (IMANI; MONTAZER, 2019).

Entretanto, com o aumento da adoção de sistemas de aprendizagem baseados na internet, gerou-se a necessidade de melhorar os métodos de acompanhamento dos alunos à distância. Uma das formas de acompanhamento dos alunos é o reconhecimento de emoções durante o processo de aprendizagem. Reconhecer as emoções dos alunos é importante, pois, na literatura, vários trabalhos comprovaram a interdependência entre desempenho de aprendizagem e as emoções (KOUAHLA et al., 2022).

Para reconhecer as emoções humanas podemos utilizar métodos de visão computacional, em inglês Computer Vision (CV). A CV é um campo de pesquisa que visa replicar a visão humana em máquinas. Entre as diversas aplicações da CV, o reconhecimento de expressões faciais, em inglês Facial Expression Recognition (FER), vem ganhando destaque nos últimos anos. O FER visa analisar expressões da face humana para classificação em rótulos predeterminados (LI; LIMA, 2021; YANG et al., 2018). Recentemente, as CNNs se tornaram uma das abordagens mais notáveis para tarefas relacionadas à classificação e reconhecimento de imagens (WANG et al., 2022; ZHU; CHEN, 2020).

Um dos grandes desafios dos modelos de CNN é a dependência de uma grande quantidade de dados rotulados. Visando mitigar a dependência de grandes conjuntos de dados e melhorar a eficiência dos modelos de CNN, a transferência de aprendizagem, em inglês Transfer Learning (TL), é um método usado para transferir o conhecimento adquirido em uma tarefa para resolver outra (RIBANI; MARENGONI, 2019). No entanto, nem sempre a TL apresenta efeitos positivos, a depender do contexto de utilização, a TL pode, inclusive, piorar o desempenho das CNNs, fenômeno conhecido como transferência negativa.



Diante disso, esse trabalho tem como objetivo avaliar a técnica de TL em modelos de CNN para aplicação em FER, visando uma posterior utilização em imagens faciais de alunos. Reconhecer as emoções por meio de expressões faciais é fundamental para qualquer modelo de ensino, pois permite projetar melhores estratégias, modelos de aprendizagem adequados e, conseqüentemente, melhorar os ganhos na realização do processo de ensino e aprendizagem (IMANI; MONTAZER, 2019).

2. REFERENCIAL TEÓRICO

2.1. REDES NEURAIAS CONVOLUCIONAIS

Em 1959, Hubel e Wiesel descobriram que as células do córtex visual animal são responsáveis pela detecção de luz em campos receptivos. Inspirado por essa descoberta, Kunihiko Fukushima propôs o Neocognitron em 1980, que pode ser considerado o antecessor das *CNN* (GU et al., 2018). Posteriormente, o modelo apresentado por Fukushima seria a inspiração utilizada para o desenvolvimento das primeiras *CNNs*.

Anos depois, (LECUN; BENGIO; HINTON, 2015) propuseram a primeira *CNN* multicamadas, chamada *ConvNet*. A *ConvNet* possuía um treinamento supervisionado usando o algoritmo de retropropagação, diferentemente de sua antecessora Neocognitron, que utilizava um esquema de aprendizado por reforço não supervisionado (LINDSAY, 2021). Em 1998, LeCuN propôs uma versão aprimorada da *ConvNet*, conhecida como LeNet-5, e iniciou o uso da *CNN* na classificação de caracteres em aplicativos relacionados ao reconhecimento de documentos (KHAN et al., 2020). A partir desse momento, criou-se as bases para os modelos de *CNNs* atuais.

Existem inúmeras variantes de arquiteturas *CNN* na literatura. No entanto, seus componentes básicos são muito semelhantes (GU et al., 2018). Nesse sentido, uma arquitetura de *CNN* típica compreende camadas alternadas de convolução e agrupamento seguidas por uma ou mais camadas totalmente conectadas no final (KHAN et al., 2020).



A camada convolucional é composta por um conjunto de *kernels* convolucionais, onde cada neurônio atua como um *kernel*. Devido à capacidade de compartilhamento de peso da operação convolucional, diferentes conjuntos de recursos dentro de uma imagem podem ser extraídos pelo *kernel* (LI et al., 2022). Geralmente, uma *CNN* possui algumas camadas convolucionais. Assim, cada camada consegue extrair recursos diferentes da entrada. As primeiras camadas extraem recursos de nível inferior, como arestas, pontos finais e cantos. As camadas de nível superior extraem recursos mais complexos processando os recursos de nível inferior (WANG; YANG, 2019). As camadas convolucionais possuem dois hiperparâmetros principais, o preenchimento, em inglês *Padding*, e o passo, em inglês *Stride*. O preenchimento pode ser utilizado para aumentar a entrada adicionando zeros. Já o passo controla a distância ao mover o *kernel* sobre uma imagem.

Após o processamento da camada convolucional, temos como saída um mapa de recursos, que é passado como entrada para uma camada de agrupamento. A camada de agrupamento, em inglês *Pooling*, tem como função reduzir gradativamente o tamanho espacial dos dados, minimizando o número de parâmetros da rede e proporcionando a diminuição do consumo de recursos computacionais. Além disso, a camada de agrupamento também pode aprender alguns recursos invariáveis da entrada (QIN et al., 2018; WANG; YANG, 2019). O agrupamento máximo é o tipo de agrupamento mais aplicado, ele recupera os maiores valores em um mapa de recursos.

No final de uma *CNN*, a saída da última camada de agrupamento atua como entrada para a camada totalmente conectada, em inglês *Fully Connected*. Totalmente conectada significa que todos os neurônios de uma camada estão conectados a todos os neurônios da próxima camada (GU et al., 2018; TAMMINA, 2019). A camada totalmente conectada recebe informações da etapa de extração de recursos, analisa globalmente a saída de todas as camadas anteriores e produz uma classificação (KHAN et al., 2020).

De maneira geral, as *CNNs* começam envolvendo um conjunto de filtros com uma



imagem de entrada, gerando, com isso, mapas de recursos semelhantes. Logo depois, o agrupamento é aplicado, criando respostas mais complexas e aprendendo recursos invariáveis da imagem de entrada. Após várias iterações desse padrão, camadas totalmente conectadas são adicionadas e a última camada contém tantos neurônios quanto o número de categorias para classificação, e, por fim, gera-se um rótulo de categoria para a imagem (LINDSAY, 2021). Neste trabalho, vamos utilizar os seguintes modelos de *CNN*: VGG16, ResNet50, MobileNetV2 e RegNet.

2.1.1. VGG16

O modelo VGG é uma *CNN* que utiliza uma estratégia de aplicação de filtros convolucionais muito pequenos, de 3x3. Essa estratégia permitiu aumentar a profundidade do modelo entre 16 e 19 camadas de pesos e, além disso, melhorou o desempenho da VGG em comparação com modelos anteriores de *CNN* (WANG; YANG, 2019). A versão com 16 camadas do modelo VGG, ficou conhecida como VGG16.

2.1.2. ResNet50

Os modelos de *CNN* do tipo ResNet foram desenvolvidos visando solucionar o problema do gradiente de fuga em modelos de *CNN* muito profundos. Diante disso, vários tipos de ResNet foram desenvolvidos com diferentes números de camadas, começando com 34 camadas e indo até 1202 camadas. O modelo mais comum de ResNet é o ResNet50, que compreende 49 camadas convolucionais mais uma única camada totalmente conectada (ALZUBAIDI et al., 2021; WANG; YANG, 2019).

O modelo ResNet é construído, principalmente, por blocos de aprendizado residual, o que permite a conectividade entre camadas. Os modelos ResNet tem o potencial de evitar problemas de diminuição de gradiente, pois os blocos de aprendizagem residual aceleram a convergência profunda da rede. A ResNet foi a rede vencedora do campeonato 2015-ILSVRC com 152 camadas de profundidade, isso representa 8 vezes a profundidade do modelo VGG (ALZUBAIDI et al., 2021).

2.1.3. MobileNetV2



O modelo MobileNetV2 aplica a técnica de Convoluções Separáveis em Profundidade, em inglês *Depthwise Separable Convolutions (DSC)*, para introduzir portabilidade a rede. As *DSCs* mitigaram o problema de destruição de informações em camadas não lineares, em blocos de convolução, usando gargalos lineares, mas também estabeleceram uma nova estrutura chamada Resíduos Invertidos, que conseguem preservar as informações no modelo (DONG et al., 2020).

2.1.4. RegNetX002

A RegNet é um modelo que combina as vantagens do design manual e da pesquisa de arquitetura de rede, em inglês *Network Architecture Search (NAS)*. O espaço de *design* RegNet pode funcionar perfeitamente em uma ampla gama de regimes de operações de ponto flutuante por segundo, pois é uma rede simples e rápida. A depender das configurações de treinamento, o modelo RegNet supera o popular modelo EfficientNet, em até 5 vezes na *GPU* (CHAI et al., 2021). Neste trabalho, utilizamos o modelo RegNetX002.

2.2. TRANSFERÊNCIA DE APRENDIZAGEM

A *TL* é um tópico emergente que pode impulsionar o sucesso da aprendizagem de máquina na pesquisa e na indústria. Este procedimento visa ajudar a melhorar a precisão ou reduzir o tempo de treinamento dos modelos de aprendizagem de máquina. Do mesmo modo, tendo em vista que coletar e rotular dados pode ser muito caro e demorado, a *TL* pode ajudar, também, a mitigar o impacto negativo decorrente da utilização de conjuntos de dados pequenos, pois permite que tais modelos possam alcançar resultados melhores com poucos dados (RIBANI; MARENGONI, 2019).

Uma das formas de aplicação da *TL* é por meio do ajuste fino. Nessa estratégia, os pesos de uma ou mais camadas dos modelos de *CNN* podem ser ajustados durante a fase de treinamento (SABATELLI et al., 2019). Na prática, em vez de inicializar aleatoriamente os parâmetros dos modelos de *CNN*, tais modelos utilizam parâmetros que foram aprendidos em algum conjunto de dados de grande escala, sendo frequentemente utilizado o conjunto de dados ImageNet, pois contém 1.4 milhão de imagens com 1.000 classes distintas (KENSERT; HARRISON; SPJUTH, 2019; RIBANI; MARENGONI, 2019).

3. ENCAMINHAMENTOS METODOLÓGICOS



3.1. CONJUNTO DE DADOS

O conjunto de dados utilizado no presente trabalho é o FER2013, que contém imagens em escala de cinza, no formato 48x48, das sete emoções básicas: raiva, nojo, medo, alegria, tristeza, surpresa e neutra, totalizando 35887 imagens (GOODFELLOW et al., 2013). O conjunto FER2013 foi escolhido para realização dos experimentos, pois é um banco público de imagens e de fácil acesso. A Figura 1 demonstra algumas imagens do conjunto FER2013.

Figura 1. Exemplos de imagens do conjunto FER2013.



Fonte: (GOODFELLOW et al., 2013).

3.2. PRÉ-PROCESSAMENTO

3.2.1. AUMENTAÇÃO DE DADOS

A aumento de dados consiste em aumentar artificialmente o tamanho de um conjunto de dados de treinamento, utilizando, para isso, transformações nos dados e preservando os respectivos rótulos de classe. Essa técnica parte da suposição de que mais informações podem ser extraídas do conjunto de dados original por meio de dados gerados a partir das transformações resultantes da aumento de dados (SHORTEN; KHOSHGOFTAAR, 2019).



Para realização dos experimentos deste trabalho e visando obter melhores resultados, aplicamos a técnica de aumento de dados no conjunto de dados FER2013 com o auxílio da biblioteca Keras. Ao final da etapa de aumento de dados, aplicamos a técnica de normalização, que permite alteração na faixa de valores de *pixels* das imagens transformando os valores de 0 até 255 para valores entre 0 e 1. Isso é importante, pois permite uma melhor convergência aos modelos de *CNN*.

3.2.2. EXTRAÇÃO DE RECURSOS E CLASSIFICAÇÃO DE IMAGENS

A extração de recursos e a classificação são duas etapas realizadas em conjunto, pois os modelos de *CNN* são projetados para realizar tanto a extração de recursos quanto a classificação de imagens de forma simultânea. No presente trabalho utilizamos as *CNNs* VGG16, ResNet50, MobileNetV2 e RegNetX002. Para todos os modelos, substituímos as camadas totalmente conectadas para permitir a classificação em apenas sete classes. Aplicamos em cada modelo a técnica de *TL* com ajuste fino, permitindo que os modelos refinem seu conhecimento prévio.

3.2.3. TREINAMENTO DOS MODELOS DE CNN

O treinamento das *CNNs* foi realizado com 80% dos dados do conjunto FER2013, totalizando 29.068 imagens. Paralelamente, a validação acontecia com 10% dos dados, totalizando 3230 imagens. Além disso, o treinamento dos modelos de *CNN* foi realizado com 100 épocas, utilizando uma técnica do Keras conhecida como parada antecipada, em inglês *Early Stopping*. A parada antecipada recebe uma métrica, que será monitorada, e interrompe o treinamento de um modelo quando essa métrica parar de melhorar. A métrica escolhida para monitoramento da parada antecipada foi a perda de validação. Por fim, a *TL* foi realizada em todos os modelos de *CNN* utilizando ajuste fino e o pré-treinamento foi realizado no conjunto de dados Imagenet. Os hiperparâmetros utilizados no otimizador das *CNNs* durante o treinamento são apresentados na Tabela 1.



Tabela 1. Hiperparâmetros do otimizador.

Hiperparâmetro	Valor
<i>Learning Rate</i>	0.001
<i>Beta_1</i>	0.9
<i>Beta_2</i>	0.999
<i>Epsilon</i>	1e-7

Fonte: O autor.

3.2.4. TESTE DOS MODELOS DE CNN

Na etapa de teste, 10% dos dados foram utilizados, o que resultou em 3589 imagens. Durante esta etapa, os modelos de *CNN*, anteriormente treinados e com os pesos salvos, são carregados e utilizados para inferência em dados de teste, ou seja, dados que nunca foram apresentados aos modelos. Ainda durante a etapa de teste, as métricas de desempenho foram extraídas de cada *CNN*.

4. RESULTADOS E DISCUSSÃO

Durante a fase de teste, os modelos de *CNN* foram avaliados de acordo com as seguintes métricas de desempenho: acurácia, precisão, revocação e pontuação-F1. Os resultados das métricas de desempenho para cada modelo de *CNN* são apresentados na Tabela 2.

Tabela 2. Desempenho dos modelos de *CNN*.

<i>CNNs</i>		Métricas			
		Acurácia	Precisão	Revocação	Pontuação-F1
VGG16	Sem <i>TL</i>	0.62	0.51	0.54	0.50
	Com <i>TL</i>	0.65	0.65	0.65	0.62
ResNet50	Sem <i>TL</i>	0.60	0.58	0.51	0.50
	Com <i>TL</i>	0.62	0.59	0.54	0.54
MobileNetV2	Sem <i>TL</i>	0.37	0.24	0.30	0.23
	Com <i>TL</i>	0.63	0.62	0.55	0.56
RegNetX002	Sem <i>TL</i>	0.61	0.61	0.54	0.55
	Com <i>TL</i>	0.60	0.60	0.54	0.55

Fonte: O autor.

Por meio da Tabela 2, podemos observar que o modelo VGG16 com *TL* obteve o melhor resultado em todas as métricas de desempenho durante a fase de teste. Em contrapartida, é possível perceber também que o modelo MobileNetV2, sem *TL*, apresentou o pior desempenho em todas as métricas. Porém, quando utilizamos o mesmo modelo aplicando a técnica de *TL*, ele obtém um desempenho competitivo com as demais *CNNs*. Isso aponta para uma alta sensibilidade do modelo MobileNetV2 a técnica de *TL* em dados de FER. Além disso, de modo geral, todos os modelos de *CNN* para FER aplicados neste trabalho alcançaram melhores resultados quando aliados à técnica de *TL*, fornecendo evidências de que a *TL* é benéfica para as *CNNs* quando aplicadas ao problema de FER.



5. CONCLUSÕES

As emoções são fundamentais em vários aspectos na vida dos seres humanos, e na educação não é diferente. Diante disso, o presente trabalho buscou avaliar, por meio de métricas de desempenho, a aplicação da técnica de *TL* em modelos de *CNN* para *FER*, visando, posteriormente, sua utilização no contexto escolar para identificação das emoções dos alunos.

Diante disso, este trabalho comparou as *CNNs* VGG16, ResNet50, MobileNetV2 e RegNetX002, com *TL* e sem *TL* para *FER*. Os resultados obtidos foram satisfatórios, com o modelo VGG16, na versão com *TL*, apresentando os melhores resultados em todas as métricas de desempenho utilizadas.

Foi visto que quando a técnica de *TL* foi aplicada aos modelos de *CNN*, seus respectivos desempenhos melhoraram significativamente, o que fornece evidências de que a *TL* seria benéfica para as *CNNs* com dados de *FER*. Portanto, concluímos que o desempenho das *CNNs* pode ser melhorado na tarefa de *FER* quando aplicamos a *TL* com ajuste fino.

REFERÊNCIAS

ALZUBAIDI, L. et al. Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. **Journal of Big Data**, v. 8, n. 1, p. 53, 31 dez. 2021.

BAYLARI, A.; MONTAZER, G. A. Design a personalized e-learning system based on item response theory and artificial neural network approach. **Expert Systems with Applications**, v. 36, n. 4, p. 8013–8021, maio 2009.

CHAI, J. et al. Deep learning in computer vision: A critical review of emerging techniques and application scenarios. **Machine Learning with Applications**, v. 6, p. 100134, dez. 2021.

DONG, K. et al. **MobileNetV2 Model for Image Classification**. 2020 2nd International Conference on Information Technology and Computer Application (ITCA). **Anais...IEEE**, dez. 2020. Disponível em: <<https://ieeexplore.ieee.org/document/9422058/>>

GOODFELLOW, I. J. et al. Challenges in Representation Learning: A Report on Three Machine Learning Contests. In: [s.l: s.n.]. p. 117–124.



GU, J. et al. Recent advances in convolutional neural networks. **Pattern Recognition**, v. 77, p. 354–377, maio 2018.

IMANI, M.; MONTAZER, G. A. A survey of emotion recognition methods with emphasis on E-Learning environments. **Journal of Network and Computer Applications**, v. 147, p. 102423, dez. 2019.

KENSERT, A.; HARRISON, P. J.; SPJUTH, O. Transfer Learning with Deep Convolutional Neural Networks for Classifying Cellular Morphological Changes. **SLAS Discovery**, v. 24, n. 4, p. 466–475, abr. 2019.

KHAN, A. et al. A survey of the recent architectures of deep convolutional neural networks. **Artificial Intelligence Review**, v. 53, n. 8, p. 5455–5516, 21 dez. 2020.

KOUAHLA, M. N. et al. Emorec: a new approach for detecting and improving the emotional state of learners in an e-learning environment. **Interactive Learning Environments**, p. 1–19, 18 fev. 2022.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, v. 521, n. 7553, p. 436–444, 28 maio 2015.

LI, B.; LIMA, D. Facial expression recognition via ResNet-50. **International Journal of Cognitive Computing in Engineering**, v. 2, p. 57–64, jun. 2021.

LI, Z. et al. A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects. **IEEE Transactions on Neural Networks and Learning Systems**, v. 33, n. 12, p. 6999–7019, dez. 2022.

LINDSAY, G. W. Convolutional Neural Networks as a Model of the Visual System: Past, Present, and Future. **Journal of Cognitive Neuroscience**, v. 33, n. 10, p. 2017–2031, 1 set. 2021.

QIN, Z. et al. How convolutional neural networks see the world --- A survey of convolutional neural network visualization methods. **Mathematical Foundations of Computing**, v. 1, n. 2, p. 149–180, 2018.

RIBANI, R.; MARENGONI, M. A Survey of Transfer Learning for Convolutional Neural Networks. 2019 32nd SIBGRAPI Conference on Graphics, Patterns and Images Tutorials



(SIBGRAPI-T). **Anais...IEEE**, out. 2019Disponível em:

<<https://ieeexplore.ieee.org/document/8920338/>>

SABATELLI, M. et al. Deep Transfer Learning for Art Classification Problems. In: [s.l: s.n.]. p. 631–646.

SHORTEN, C.; KHOSHGOFTAAR, T. M. A survey on Image Data Augmentation for Deep Learning. **Journal of Big Data**, v. 6, n. 1, p. 60, 6 dez. 2019.

TAMMINA, S. Transfer learning using VGG-16 with Deep Convolutional Neural Network for Classifying Images. **International Journal of Scientific and Research Publications (IJSRP)**, v. 9, n. 10, p. p9420, 6 out. 2019.

WANG, W.; YANG, Y. Development of convolutional neural network and its application in image classification: a survey. **Optical Engineering**, v. 58, n. 04, p. 1, 11 abr. 2019.

WANG, Y. et al. A systematic review on affective computing: emotion models, databases, and recent advances. **Information Fusion**, v. 83–84, p. 19–52, jul. 2022.

YANG, B. et al. Facial Expression Recognition Using Weighted Mixture Deep Neural Network Based on Double-Channel Facial Images. **IEEE Access**, v. 6, p. 4630–4640, 2018.

ZHU, X.; CHEN, Z. Dual-modality spatiotemporal feature learning for spontaneous facial expression recognition in e-learning using hybrid deep neural network. **The Visual Computer**, v. 36, n. 4, p. 743–755, 3 abr. 2020.



QUEBRANDO A TENSÃO DE APRENDER QUÍMICA COM ATIVIDADES FEITAS FORA DA SALA DE AULA: UM RELATO SOBRE O “CIÊNCIA NO INTERVALO”

Carlos Henrique Tenório de Lima

Licenciando em Ciências Exatas

Universidade Federal do Paraná - Campus avançado Jandaia do Sul

carlos1@ufpr.br

André Degaspere Almeida

Licenciando em Ciências Exatas

Universidade Federal do Paraná - Campus avançado Jandaia do Sul

andredegaspere@ufpr.br

Tania do Carmo

Doutora em Educação em Ciências e Matemática

Universidade Federal do Paraná - Campus avançado Jandaia do Sul

tania.carmo@ufpr.br

Ana Claudia Nogueira Mulati

Doutora em Física

Universidade Federal do Paraná - Campus avançado Jandaia do Sul

anacnogueira@ufpr.br

Marcelo Valério

Doutor em Educação em Ciências e Matemática

Universidade Federal do Paraná - Campus avançado Jandaia do Sul

marcelovalerio@ufpr.br



RESUMO

Este trabalho relata uma das experiências formativas desenvolvidas no âmbito do projeto de extensão “ExataMente”, que tem como um de seus objetivos a promoção de práticas de popularização de ciências e matemática junto a públicos escolares. Trata-se da atividade intitulada “Ciência no Intervalo”, quando os estudantes do projeto desenvolvem e apresentam atividades práticas e simulam experimentos científicos nos momentos e espaços de intervalo ou “recreio” das escolas parceiras. Para este relato foi selecionada a atividade chamada de “Leite Psicodélico”, com a qual se exploram conceitos químicos como Misturas e Tensão Superficial. A abordagem do “Ciência no Intervalo” é sempre interativa e lúdica, pautada por relações com o cotidiano do público, visando a interação e participação, e provoca um diálogo dos participantes com os conceitos e fenômenos de modo sensorial, concreto. Tem-se percebido haver interesse, curiosidade e mesmo motivação dos estudantes-participantes em conhecer e aprofundar questionamentos sobre os temas que foram abordados. No caso específico da Tensão Superficial, percebeu-se interesse teórico dos participantes em compreender com maior clareza os conceitos envolvidos. Para os membros do projeto, que precisam trabalhar intervenções rápidas em pequenas estações nos pátios das escolas, trata-se de um aprendizado teórico e comunicativo bastante relevante em sua formação.

PALAVRAS-CHAVE: Licenciaturas; Ensino de química; Popularização da ciência; Divulgação científica; Formação inicial docente.

1. CONTEXTUALIZANDO O CIÊNCIA NO INTERVALO

Promover experiências positivas frente às Ciências e a Matemática é um dos interesses do projeto de extensão ExataMente, desenvolvido pela Universidade Federal do Paraná - *campus* avançado de Jandaia do Sul. Sua intenção é construir espaços de diálogo entre a universidade-escola e inserir os/as estudantes, principalmente da Licenciatura em Ciências Exatas, no contexto escolar da Educação Básica desde os primeiros períodos do curso.

Projetos como o ExataMente contribuem para a superação do distanciamento entre as escolas e a formação inicial docente (GATTI, 2010), levando para a escola práticas pedagógicas que incrementam o processo de ensino e aprendizagem dos estudantes da educação básica. Neste sentido, a interação entre universidade-escola pode contribuir para



uma melhor formação de professores e a permanência dos licenciandos no curso, ao se integrarem ao desenvolvimento de atividades que favorecem a superação das dificuldades do processo de ensino e aprendizagem, principalmente nas disciplinas da área de ciências exatas, que tem tido um grande desinteresse e evasão (AGOSTINI; MASSI, 2017; SÁ; SANTOS, 2012; LAPO; BUENO, 2001).

Conforme Brasil (2015), esta escassez de professores na educação básica, principalmente nas disciplinas de física, matemática e química implica, cada vez mais estudantes do ensino fundamental e médio serem atendidos por professores sem formação específica nessas disciplinas (BRASIL, 2015).

Conforme Souza Neto, Borges e Ayoub (2021), a parceria entre universidade e escola é uma ação de muita relevância para o processo de formação docente. Já há na literatura nacional e internacional uma sintonia sobre a importância desta cooperação. Contudo, como é sabido entre aqueles/as que atuam nas redes de ensino e no campo da formação docente, as questões operacionais, técnicas, os tempos ou mesmo a sinergia entre as pessoas pode tornar as relações um tanto desafiadoras - quando não, pontuais, descontínuas e até esporádicas. Por conta disso, no âmbito do ExataMente, acolheu-se ainda a ideia de que os/as estudantes atuassem também em/com abordagens educativas não-formais (MARANDINO, 2003). E outros espaços e tempos, paralelos àqueles destinados ao ensino formal, às aulas, propriamente ditas, passaram a ser contemplados como possíveis campos de intervenção pedagógica.

Nesse contexto, em meio a um conturbado calendário escolar de período pós-greve, ainda em 2015, houve as primeiras iniciativas do chamado Ciência no Intervalo - uma ação que consiste em levar atividades investigativas, práticas e lúdicas para o pátio da escola nos intervalos das aulas. Desde então, o sucesso dessas iniciativas vêm sendo relatado pelos estudantes em vários eventos, em um processo também formativo de sistematização de suas experiências, em trabalhos como Gonçalves (2016); Blasques (2018); Viana (2018); Domingues (2019).

Durante os anos de 2020 e 2021, obviamente, não houve ações do Ciência no Intervalo por conta do fechamento das escolas e de todas as medidas de distanciamento social e preservação da vida necessárias para o enfrentamento à pandemia do novo coronavírus - Sars-Cov-2. Somente em 2022, portanto, as atividades puderam ser reorganizadas e



retomadas, com a reestruturação do projeto, restabelecimento da equipe de trabalho, firmamento de novas parcerias com escolas e novas ideias de ações a se empreender. Em 2023, então, o Ciência no Intervalo esteve presente nas escolas de Jandaia do Sul, parceiras do projeto, durante todo o primeiro semestre, atendendo um público aproximado de 150 estudantes da educação básica.

Neste cenário, o objetivo deste trabalho é relatar uma das atividades propostas e desenvolvidas no Ciência no Intervalo, intitulada “Leite Psicodélico”, sobre a qual foram demonstrados conceitos químicos como Misturas e Tensão Superficial, para estudantes de escolas públicas da cidade de Jandaia do Sul.

Nesse processo, as questões relacionadas às competências comunicativas, à interação com o público, ao domínio dos conceitos teóricos, ao repertório de recursos para explicar os fenômenos científicos, as ilustrações, exemplos e vínculos cotidianos, são importantes e formidáveis experiências pedagógicas e didáticas para os estudantes do projeto, em uma genuína formação em ação. O caráter descontraído da atividade, menos sisuda ou hierárquica que uma aula geralmente é planejada, digamos, costuma tornar a experiência prazerosa e seu relato e reflexão bastante proveitosos quando do retorno à universidade.

2. DESCRIÇÃO DA ATIVIDADE DO LEITE PSICODÉLICO

A ideia de explorar o “Leite Psicodélico” como foco do primeiro “Ciência no Intervalo” de 2023 surgiu durante uma reunião entre os membros do projeto de extensão. A escolha desse tema foi motivada por permitir que o público interagisse e realizasse a atividade conjuntamente com os apresentadores, além da facilidade de estabelecer uma conexão com a preparação de achocolatados, visando aproximar conceitos científicos do cotidiano dos estudantes. Com isso em mente, após a definição das atividades a serem realizadas, o planejamento foi cuidadosamente desenvolvido para despertar a curiosidade, a participação e o interesse dos alunos pelo assunto tratado.

As atividades foram estruturadas em uma estação montada nas carteiras escolares, estrategicamente posicionadas no pátio das escolas, próximo onde costumam fazer a merenda durante os intervalos das aulas. Isso permitiu uma abordagem prática e envolvente,



aproveitando um local de trânsito frequente para atrair a atenção dos estudantes para a experiência. As Figuras 1 e 2, representam um dos momentos de aplicação da atividade.

Figura 1 - Bolsistas apresentando o leite psicodélico



Fonte: Os Autores

Figura 2 - Estudantes realizando a experiência



Fonte: Os Autores

Utilizando diferentes marcas de achocolatado em pó, os alunos exploraram a tensão superficial durante a atividade de misturar o chocolate em pó com leite. Divertiram-se ao votar para ver qual marca se comportaria melhor. Apesar da abordagem lúdica, os Licenciandos discutiram por que os ingredientes não se misturavam facilmente sem agitação. Com o achocolatado em pó, notaram que, devido à tensão superficial do leite, o pó formava uma camada seca ao redor de si ao ser retirado do líquido, em vez de se misturar completamente.

Na atividade "Leite Psicodélico", os estudantes explicaram a adição dos ingredientes necessários para alcançar uma agitação mais eficaz. A tarefa envolvia a preparação de pratos descartáveis com leite, ao qual adicionaram várias cores de corantes alimentares, três gotas de cada. Um copo descartável de 50mL com detergente líquido era usado para mergulhar em cotonetes de higiene pessoal. Ao colocar os cotonetes no centro dos pratos, o detergente reduzia a tensão superficial do leite, permitindo que as moléculas de corante e leite interagissem livremente, criando padrões em constante mudança descritos como "psicodélicos".

Todas as atividades foram acompanhadas por questionamentos elaborados pelos alunos bolsistas e professores orientadores do projeto, incentivando os estudantes a validar suas ideias pré-concebidas e a compreender melhor os fenômenos em questão, além de promover a interação com os licenciandos.



3. APRECIÇÃO DA ATIVIDADE E RESULTADOS FORMATIVOS


Desde sua concepção as atividades (as estações de trabalho) foram estruturadas para causar impacto visual, chamarem atenção e serem atraentes para o público escolar assim que fossem liberados para o horário de seu intervalo, estimulando curiosidade e oferecendo alguma possibilidade de surpresa. Do ponto de vista pedagógico, apostou-se na ludicidade da prática, no sentido de permitir a interação, por meio da comunicação, e mesmo a manipulação de alguns elementos pelo público; e também aspectos investigativos típicos da experimentação, considerando a rotina prevista para o desenvolvimento e operacionalização do conhecimento. Entendemos que essas escolhas foram bastante coerentes, pois nas intervenções feitas houve muito acolhimento para as propostas, com bastante participação e perguntas. Desde o início, os alunos pareceram intrigados, já com o fato de verem os membros do projeto vestidos com jalecos brancos em suas bancadas (estações de trabalho montadas com mesinhas no pátio) com seus instrumentos para a experimentação.

Entre as muitas indagações que vieram surgindo, estavam frases como: "Qual é exatamente a atividade que vocês estão executando?"; "Por que tem pratos com leite e tinta?"; "Por que tem chocolate em pó?"; "O que essas coisas têm em comum?"; "O que é Tensão Superficial?".

A abordagem prática, experimental, lúdica, pautada no diálogo e na interação, tornou a abordagem conceitual menos difícil do que imaginávamos, como professores ou mediadores do conhecimento, e percebemos que o mesmo aconteceu com os quase 150 alunos participantes, do ensino fundamental e médio das escolas públicas parceiras.



Figura 3. Atividades do leite psicodélico e misturar o chocolate em pó com leite.



Fonte: Os Autores

De modo mais detalhado, cabe descrever que na estação de trabalho onde se desenvolveram as atividades, enquanto os participantes produziam o leite psicodélico, os conceitos envolvidos eram evidenciados e explicados pelos licenciandos enquanto se respondiam perguntas relacionadas à tensão superficial do leite com detergente e a formação da série de movimentos aleatórios.

Ressaltou-se que o leite possui uma tensão superficial consideravelmente alta, o que significa que a camada superficial do líquido se assemelha a uma membrana elástica, mantendo as moléculas intimamente unidas. No entanto, ao introduzir o sabão, essa tensão superficial é reduzida. Consequentemente, as moléculas que originalmente estavam em proximidade com o cotonete passam a ser atraídas pelas moléculas que estão mais afastadas, o que resulta no arraste das partículas de tinta, que acompanham esse movimento.

E mesmo esta explicação mais formal não sendo o foco da atividade, muitos estudantes se mostraram bastante interessados em aprofundá-la, trazendo novos questionamentos e simulando situações diferenciadas, novos testes e hipóteses para testar sobre o fenômeno.

As particularidades das ações empreendidas pela atividade Ciência no Intervalo têm evidenciado aos estudantes de licenciatura a relevância e necessidade de disseminação e popularização do conhecimento científico. Isso acontece porque a dinâmica e a natureza



lúdica das propostas conduzem a momentos de intercâmbio de saberes, contribuindo de maneira significativa para a formação pedagógica desses indivíduos. O afastamento da rigidez do método convencional de sala de aula tem despertado a curiosidade e estimulando a participação dos alunos. Nesse contexto, a ausência de um modelo educacional restrito transformou essa iniciativa em um período de capacitação para os estudantes em formação, preparando-os para abordagens educacionais informais.

Ao possibilitar o envolvimento direto dos estudantes com atividades científicas práticas, percebe-se o interesse deles pelo conhecimento. A participação efetiva dos alunos nas atividades se reflete na sua dedicação, alguns acompanhando as ações durante todo o intervalo das aulas, outros até trazendo colegas para se unirem, e alguns deles indagando como poderiam repetir a atividade em casa, e se poderiam substituir os ingredientes.

Souza Neto, Borges e Ayoub (2021, p.04), afirmam que

as parcerias entre escola e universidade decorrem de propostas formativas ou de dispositivos de formação docente que fazem emergir uma profícua interlocução entre escola e universidade, assim como de questionamentos, nos quais todos os atores envolvidos (docentes das universidades e das escolas, estagiários, estudantes das escolas, gestores, entre outros) são convidados a compartilhar conhecimentos, saberes e experiências que se produzem em diferentes contextos. Tais compartilhamentos têm propiciado uma série de ações colaborativas e de aprendizados que, na formação docente, se constituem em diálogo com as diferentes possibilidades cocriadas por todos que nela estão imbricados.

Por fim, não menos importante, a questão vocacional também se fez presente: os alunos de licenciatura foram abordados por estudantes da educação básica interessados no curso de Licenciatura em Ciências Exatas, demonstrando interesse em seguir carreiras na área. Pode-se dizer que isso ocorreu porque eles se sentiram empolgados e entusiasmados com as experiências práticas realizadas. Além disso, os professores das escolas parceiras mencionaram que as atividades implementadas têm alcançado os resultados desejados, uma vez que são mencionadas em sala de aula. E o oposto também é verdadeiro, pois há alunos que compartilham conceitos que foram abordados em suas aulas. Por meio de devolutivas



como essas há um fortalecimento do processo de construção do conhecimento científico por meio de ações como esta promovidas nas escolas.

4. PALAVRAS FINAIS

As iniciativas promovidas pelo "Ciência no Intervalo" adotaram abordagens lúdicas e interativas, contrastando com métodos convencionais de ensino formal presentes em salas de aulas de ciências e matemática. A utilização de recursos de baixo custo também viabilizou uma participação ampla dos alunos do ensino fundamental e médio de maneira envolvente e produtiva. Neste sentido, é possível afirmar que tais atividades despertam o interesse dos alunos, estimulando debates e interações entre eles acerca dos fenômenos observados, ao mesmo tempo que fortalecem a conexão entre aluno e professor.

Destaca-se a relevância da popularização e divulgação da Ciência como possibilidade de cativar os alunos por meio do conhecimento científico. No que se refere aos futuros educadores, a experiência vivenciada sugere que a ausência de uma estrutura de ensino rígida, aliada às atividades desafiadoras propostas, tornou a experimentação mais atrativa e acessível. Assim, alternativas metodológicas e ambientes distintos para a educação revelam-se plausíveis e proveitosos, moldando novos espaços e abordagens para instruir e disseminar o saber científico por diferentes espaços sociais.

REFERÊNCIAS

AGOSTINI, G.; MASSI, L. Atratividade e permanência na carreira docente: um estudo sobre o encaminhamento profissional de licenciados em química. In: Encontro Nacional de Pesquisa em Educação em Ciências, 11., 2017, Florianópolis. **Anais [...]**. Florianópolis: ABRAPEC, 2017. p. 1-10. Disponível em: <https://abrapec.com/enpec/xi-enpec/anais/resumos/R0349-1.pdf>. Acesso em 19 ago. 2023.

BLASQUES, D. C., VIANA, L. M. R., MENDES, L. C., MULATI, A. C. N., SILVA, V. M., NASCIMENTO, W. J. Ciência no intervalo: a água como tema para divulgação e popularização da ciência. Anais do XVI Evento de Educação em Química - EVEQ, Araraquara, 2018. Disponível em < <https://www.iq.unesp.br/#!/eveq/anais-atualizados/xvi-eveq/> > Acessado em 19 ago. 2023.



DOMINGUES, G. H. C.; NASCIMENTO, W. J.; VALÉRIO, M. Iniciação à docência em Física inspirada no ensino por investigação. **Extensão em Foco**, [S.l.], n. 19, jul. 2019. ISSN 2358-7180. Disponível em: <<https://revistas.ufpr.br/extensao/article/view/63871>>. Acesso em: 20 ago. 2023. doi:<http://dx.doi.org/10.5380/ef.v0i19.63871>.

FOGAÇA, J. Experimento do Leite Psicodélico. **Brasil Escola**: Canal do educador. Disponível em: <https://educador.brasilecola.uol.com.br/estrategias-ensino/experimento-leite-psicodelico.html>. Acesso em: 19 ago. 2023.

GATTI, B. Formação de professores no Brasil: características e problemas. **Educação & Sociedade**, Campinas, v. 31, n. 113, p. 1355-1379, out.-dez. 2010. Disponível em: <https://www.scielo.br/j/es/a/R5VNX8SpKjNmKPxxp4QMt9M/>. Acesso em: 19 ago. 2013.

LAPO, F. R.; BUENO, B. Evasão docente e abandono da profissão: um estudo com professores do magistério público do estado de São Paulo. **Educação em Debate**, Fortaleza, ano 23, v.2, n.42, p.30-42. 2001. Disponível em: https://repositorio.ufc.br/bitstream/riufc/14609/1/2001_art_frlopo.pdf. Acesso em: 19 ago. 2023.

SÁ, C. S. S.; SANTOS, W. Carência de professores de química: faltam cursos, salário ou identidade de curso? In: Encontro Nacional de Didática e Práticas de Ensino, 16., 2012, Campinas. **Anais [...]**. Campinas: Unicamp, 2012.

SILVA, F. L. I.; BENBADIS, I. F. M. Experimento do leite "psicodélico" para melhorar a compreensão do efeito entre detergente e lipídios. **Revista Encontros Universitários da UFC**. v. 1, 2016 .p. 2787. Fortaleza. UFC. 2016.

SOUZA NETO, S.; BORGES, C.; AYOUB, E. **Formação de professores na contemporaneidade: desafios e possibilidades da parceria entre universidade e escola**. **Pro. posições**, Campinas, v. 32, p. 1-10, 2021. Disponível em: <https://www.scielo.br/j/pp/a/gFgZh5rxH9mNW3VKfdzNMKj/?lang=pt&format=pdf>. Acesso em: 19 ago. 2023.



THENÓRIO, I. F. **Faça um LEITE PSICODÉLICO TURBINADO** - Manual do Mundo, 2020. [n.p.]. Disponível em: <https://www.youtube.com/watch?v=IHxL_kh1jul>. Acesso em: 17/05/2023.

TORRES, T. G.; GONCALVES, R. P. S.; VALÉRIO, M.; SHIRABAYASHI, J. V.; BRAZ, B. C. Intervalo também é tempo de matemática. In: Anais do XXXZXXII Encontro Regional de Estudantes de Matemática do Sul. Curitiba. 2016.

SIMPÓSIO DE LICENCIATURAS EM CIÊNCIAS EXATAS E EM COMPUTAÇÃO

VI SLEC

