

# Classificação de Sinais de EEG para Diagnóstico do Transtorno do Espectro Autista utilizando CNN e RNN

Josias L.S. Neto<sup>1,2</sup>, Eddie Batista L. Filho<sup>3</sup>, Sylvania C. Furtado<sup>1</sup>, Wheidima C. de Melo<sup>4</sup>, Waldir S.S. Júnior<sup>1</sup>

<sup>1</sup>Universidade Federal do Amazonas (UFAM), AM-Brasil

<sup>2</sup>Empresa Brasileira de Serviços Hospitalares (EBSERH), Brasil

<sup>3</sup>Envision/TPV Group Technology Limited, AM-Brazil

<sup>4</sup>Universidade do Estado do Amazonas (UEA), AM-Brasil

Emails: josias.neto@ebserh.gov.br, eddie.filho@tpv-tech.com, wmelo@uea.edu.br, {silvaniafurtado, waldirjr}@ufam.edu.br

**Resumo**— Pesquisas recentes indicam um crescente número de crianças diagnosticadas com TEA, o que impulsiona o estudo e desenvolvimento de novas ferramentas para diagnóstico precoce desta doença, para tratamento nos primeiros anos. O presente trabalho explora uma abordagem com CNN e RNN combinadas com técnicas de pré-processamento e extração de características, a partir da classificação de sinais de eletroencefalograma, para o diagnóstico do TEA. Utilizando-se a base de dados de Milne *et al.*, mostra-se que o melhor modelo proposto alcançou uma acurácia de classificação de 99,51%, o que corrobora a capacidade do sistema proposto em distinguir indivíduos com TEA dos tipicamente desenvolvidos.

**Palavras-Chave**— EEG, Transtorno do espectro autista, CNN, RNN.

**Abstract**— Recent research indicates a growing number of children diagnosed with ASD, which drives the study and development of new tools for early diagnosis of this disease, for treatment in the first years. The present work explores an approach with CNN and RNN combined with pre-processing and feature extraction techniques, based on the classification of electroencephalogram signals, for the diagnosis of ASD. Using the Milne *et al.* database, it is shown that the best proposed model achieved a classification accuracy of 99,51%, which confirms the ability of the proposed system to distinguish individuals with ASD from those typically developed.

**Keywords**— EEG, Autism spectrum disorder, CNN, RNN.

## I. INTRODUÇÃO

Sinais biológicos são registros das atividades elétricas dos diversos sistemas fisiológicos do corpo humano [1, 2, 3, 4]. Os principais e mais utilizados são o eletrocardiograma (ECG), o eletromiograma (EMG) e o eletroencefalograma (EEG). Tais sinais são de extrema importância, tanto para a medicina quanto para a engenharia, pois permitem monitorar o funcionamento dos seus respectivos sistemas biológicos. Além disso, alterações nos seus parâmetros podem indicar diferentes estados clínicos. Normalmente, a informação de interesse, em sinais biológicos, está permeada por elementos irrelevantes (e.g., ruído) [5, 6], o que pode dificultar seu uso. Para eliminar/mitigar esses problemas, diversos sistemas de processamento de sinais biológicos têm sido desenvolvidos. Atualmente, há diversas aplicações que utilizam, direta ou indiretamente, sinais biológicos, como identificação de condições patológicas [1, 7, 8, 2] e compressão de sinais [9, 10, 11]. O sinal biológico de EEG tem sido bastante explorado pela comunidade científica [1, 9, 6, 12, 13, 14, 3]. Isso é devido ao amplo número de aplicações médicas que o sinal possui. Como os sinais de EEG são registros da atividade elétrica do cérebro [2], pode-se empregá-los no diagnóstico e tratamento de doenças neurológicas, tais como epilepsia, Parkinson e Alzheimer [12], entre outras. Outra aplicação clínica do sinal

é o auxílio na avaliação de transtornos mentais, e.g., depressão e autismo [13, 14].

Pesquisas recentes da principal referência mundial a respeito da prevalência de autismo, o centro de controle de prevenção de doenças dos Estados Unidos (*centers for disease control and prevention*, CDC), apontam que 1 em cada 36 crianças de 8 anos são autistas nos Estados Unidos [15], número 22% maior em relação à pesquisa anterior, de 2021. O transtorno do espectro autista (TEA) é caracterizado por diversos sintomas, que impactam diretamente os campos de comportamento, comunicação e interação social [16, 17]. Normalmente o diagnóstico clínico ocorre por meio da observação sistêmica, podendo ser tardio, dada a dificuldade de detecção através de exames laboratoriais [18]. Dessa forma, alternativas para o diagnóstico precoce são fundamentais para a mitigação de prejuízos no campo social, profissional, e demais áreas de desenvolvimento destes indivíduos. Atualmente, algoritmos de aprendizado profundo vêm sendo utilizados, com certa frequência, como ferramentas de auxílio para o diagnóstico de doenças neurológicas [17, 19]. Essas técnicas permitem a análise automática de imagens médicas ou sinais fisiológicos coletados de pacientes, como os sinais EEG. Neste artigo, propõe-se explorar os classificadores LSTM, 2D-CNN, ResNet, MobileNet e Autoencoder combinados com técnicas de pré-processamento de sinais para diagnóstico de TEA, utilizando-se como entrada sinais de EEG bidimensionais gerados a partir da concatenação de canais.

## II. TRABALHOS RELACIONADOS

O trabalho proposto por Bhaskarachary *et al.* [20] teve como objetivo explorar e analisar técnicas de pré-processamento de sinais EEG, extração de características e aprendizado de máquina, visando identificar atividades anormais para o diagnóstico do transtorno do espectro autista (TEA). Para isso, os autores utilizaram a base de dados de *child mind institute biobank* [21], a qual contém 88 sinais de EEG de crianças tipicamente desenvolvidas (TD) e 100 sinais de EEG de crianças autistas. Esses sinais foram amostrados em 250 Hz e segmentados em trilhas de 20 s, extraindo-se apenas as partes relacionadas ao estado de olhos fechados. Depois, foram decompostos em quatro bandas de frequências, seguido do cálculo da densidade espectral de potência. A técnica de PCA usada para reduzir a dimensionalidade de 440 para 46 canais foi utilizada no projeto dos classificadores *extra trees* e *XGBoost*. Os desempenhos dos modelos foram avaliados através da AuC, acurácia, *recall*, precisão e especificidade. Finalmente, observou-se que os resultados de desempenho do classificador *extra trees* foram superiores em relação ao *XGBoost*, com acurácia de 67,70 %, sensibilidade de 83,30 %, especificidade de 54,30 %, precisão de 61 % e AuC de 0,74.

Kang *et al.* [16], utilizaram recursos extraídos de sinais EEG e rastreamento ocular. Um total de 97 crianças de 3 a 6 anos foram incluídas no presente estudo, 49 com TEA e 48 TD. Após a gravação de dados de EEG em estado de repouso com um sistema de rede de sensores HydroCel de 128 canais, em uma taxa de amostragem de 1 kHz, durante 6 min, as crianças realizaram testes de rastreamento ocular. Por intermédio da *toolbox* EEGLab [22], utilizou-se: filtro passa-faixa entre 0,5 e 45 Hz, reamostragem para 250 Hz, filtro *notch* centrado em 50 Hz, remoção de artefatos com ICA e inspeção visual. Para a análise dos dados de rastreamento ocular, 8 áreas de interesse (AoI) foram estabelecidas, a fim de quantificar o engajamento da criança em cada AoI. Por fim, o método de seleção de recursos de relevância máxima e redundância mínima (MRMR), combinado com o classificador SVM, foi utilizado. Os resultados mostraram que a acurácia de classificação usando a potência relativa das cinco bandas de frequência como entrada para o SVM foi de 68%. Ao olhar para estímulos faciais, a acurácia foi 75,89% e, combinando os dois tipos de dados como entrada, a acurácia foi de 85,44%.

No trabalho de Jayawardana *et al.* [17], os sinais de EEG foram coletados de 8 crianças diagnosticadas com TEA e 9 TD, com idades de 5 a 17 anos. Foi solicitado a essas crianças que completassem uma avaliação chamada *autism diagnostic observation schedule second edition* (ADOS-2) [23], enquanto simultaneamente gravavam os sinais de EEG. Esses sinais foram registrados usando o sistema EEG sem fio *LiveAmp* de 32 canais, com eletrodos ativos e uma taxa de amostragem digital de 250 Hz. Os autores derivaram os espectros de potência para cada eletrodo por meio da (i) decomposição da banda de frequência e (ii) da decomposição por transformadas Wavelet, as quais geram dois conjuntos de dados de treinamento que capturam tendências de longo e curto prazo, respectivamente. Com a EEGLab [22] utilizou-se: remoção do desvio da linha de base de baixa frequência, remoção de artefatos oculares, musculares e de movimento, referenciamento de canais, filtragem de ruídos AC de 50 a 60 Hz, rejeição de canais ruins, interpolação de canais removidos e ICA. Para classificação, utilizaram *random forest*, *logistic*, *bagging*, *JRip*, *LMT*, *AdaBoostM1* e *CNN-1D*. Como resultado, em dependências de curto prazo, obteve-se um máximo de 56% de acurácia para modelos lineares e para modelos não lineares a acurácia foi acima de 92%, com escore ADOS-2 previstas dentro de um RMSE de valor 4.

Ibrahim *et al.* [19], investigaram diferentes técnicas utilizando EEG para auxiliar no diagnóstico de epilepsia e TEA. Foram usadas 4 bases de dados: da Universidade de Bonn [24], a qual contém 5 pastas com 100 gravações de sinais epiléticos e normais de 23,60 s; do MIT [25], com 906 h de gravações de 23 pacientes epiléticos; da Universidade King Abdulaziz [26], gravados de 10 jovens TD e 9 TEA e; uma base de dados própria com gravações de EEG de 46 indivíduos [19]. Em todos os casos, os sinais de EEG foram pré-processados para remover os principais artefatos indesejados, antes de serem decompostos em várias sub-bandas de EEG por meio da DWT. Em seguida, aplicaram-se as funções desvio padrão (SD), potência de banda (BP), entropia de *Shannon* e maior expoente de *Lyapunov*, sendo as duas últimas métodos não-lineares que medem complexidade e caoticidade no registro do EEG. Diferentes métodos de classificação foram usados como NN, kKNN, SVM e LDA. Por fim, a combinação das técnicas de DWT, entropia de *Shannon* e classificador kNN produziu o resultado de classificação mais promissor, com uma acurácia de até 94,62% para o problema de classificação de três classes (multicanal).

Em [27], Milne *et al.* examinaram as características compor-

tamentais do autismo juntamente com os métodos de coerência de fase entre as tentativas (ITC) e entropia multiescala (MSE), calculados a partir de sinais de EEG. Os dados para os experimentos foram obtidos de 99 adultos, sendo 38 diagnósticos com TEA (19 mulheres), adquiridos via *BioSemi ActiveTwo* em uma câmara blindada eletricamente durante estimulação visual e repouso com os olhos fechados. Canais e segmentos de dados contaminados por artefatos grosseiros foram identificados e removidos por meio de inspeção visual. Além disso, os dados foram decompostos em componentes independentes (IC) usando o algoritmo *runica* do *EEGLab*. Os autores descobriram que ITC e MSE têm maior probabilidade de serem reduzidos em pessoas com TEA. A análise da função discriminante (DFA) inserindo MSE e ITC como preditores de associação de grupo (diagnosticados e não-diagnosticados) foi realizada. A associação entre grupo e preditores foi significativa, no entanto, enquanto 18 dos 22 (81,80%) participantes não-diagnosticados foram classificados corretamente, apenas 12 dos 22 (54,50%) participantes diagnosticados foram classificados corretamente. Na associação entre grupo e ITC, 81,80% dos participantes não-diagnosticados foram classificados corretamente e 50% no grupo dos diagnosticados. Por fim, a associação entre grupo e MSE também foi significativa, porém apenas 63,60% dos participantes não-diagnosticados e 59,10% dos participantes diagnosticados foram classificados corretamente. A DFA mostrou que as variáveis do EEG não distinguiam claramente os participantes diagnosticados dos não-diagnosticados.

### III. SISTEMA DE CLASSIFICAÇÃO UTILIZANDO EEG PARA DIAGNÓSTICO DO TEA

#### A. Introdução

Neste trabalho, propõe-se um sistema de classificação de sinais EEG para o diagnóstico precoce do TEA utilizando técnicas de pré-processamento e aprendizagem profunda. O sistema proposto busca investigar a existência de padrões em sinais de EEG bidimensionais (imagens), gerados a partir de sinais unidimensionais, que distingam indivíduos diagnosticados com TEA daqueles tipicamente desenvolvidos (TD), a partir da observação de resultados das principais métricas de avaliação de desempenho de CNN e redes neurais recorrentes (RNN), a saber, acurácia, área sob a curva (AuC), erro, precisão, *recall* e *f1-score*. Para fins de validação do modelo proposto, utiliza-se a base de dados disponibilizada por Milne *et al.*, da Universidade de *Sheffield* [28], a qual contém 56 sinais: 28 de indivíduos diagnosticados previamente com TEA e outros 28 TD, com idades entre 18 e 68 anos e duração de 150 s de gravação para cada sinal. Os dados foram coletados pelo sistema *biosemi active two EEG*, de 64 canais, e a aprovação ética para coleta e compartilhamento de dados foi concedida pela *health research authority* [29]. O sistema completo é composto principalmente por duas etapas: (i) pré-processamento dos sinais obtidos (Figura 1) e; (ii) treinamento e classificação (Figura 2).

#### B. Pré-processamento

Para cada sinal EEG (veja Figura 1), na etapa de reamostragem dos sinais, realiza-se a redução da taxa de amostragem de 512 Hz para 256 Hz e 128 Hz, a fim de se investigar o possível aumento na velocidade de processamento e diminuição da memória de armazenamento sem comprometer a extração de características e o reconhecimento de padrões nos sinais. Com filtros passa-baixa e passa-alta, busca-se delimitar entre 1 e 60 Hz a frequência de amplitude dos sinais, quando estes são visualizados pela perspectiva do domínio da frequência.

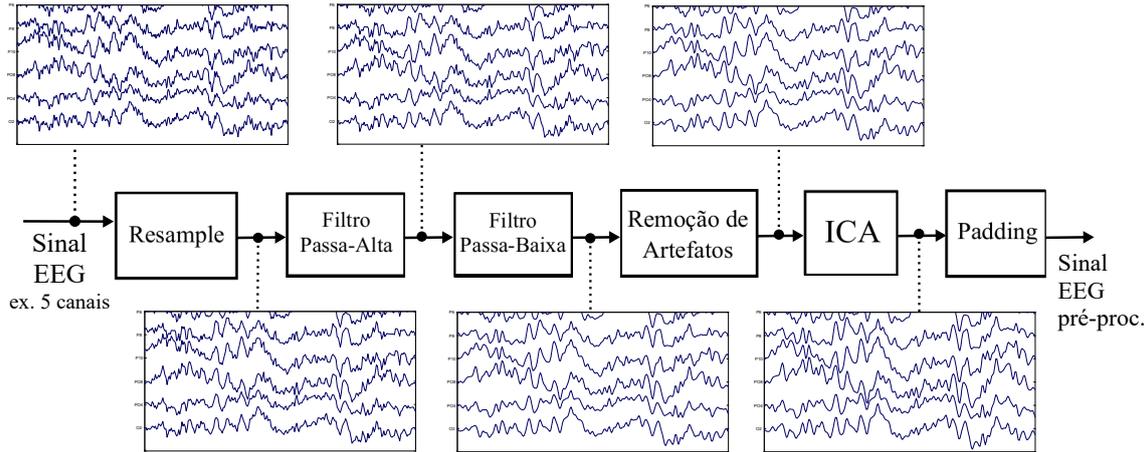


Fig. 1. Diagrama em blocos para pré-processamento para o sistema de classificação TEA. Para uma melhor visualização das saídas e entradas dos blocos, exibe-se um pré-processamento com 5 canais apenas. Em nosso trabalho, utiliza-se um total de 64 canais.

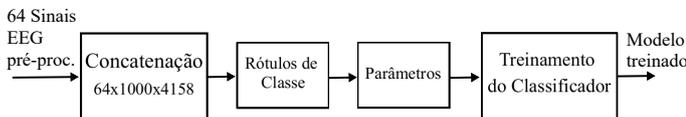


Fig. 2. Diagrama em blocos para classificação para o sistema de classificação TEA.

Por convenção, adota-se a seguinte decomposição em cinco bandas de frequência: delta (1 – 4 Hz), teta (4 – 8 Hz), alfa (8 – 13 Hz), beta (13 – 30 Hz) e gama (30 – 60 Hz), onde estão concentradas as principais atividades neurais em um cérebro humano, de acordo com Sanei *et al.* [30]. Em seguida, utiliza-se a ferramenta de rejeição automática de artefatos com o plugin *clean rawdata*, o qual remove canais planos maiores que 5s, canais com ruídos de alta frequência com desvio padrão maiores que 4 em relação aos demais e canais com correlação inferior a 80% em relação aos demais. Por fim, aplica-se a técnica de podagem com análise de componentes independentes para remoção de artefatos com 80% de chances ou mais de estarem relacionados a movimentos de músculos ou olhos, quando da coleta de dados.

Em razão dos procedimentos aplicados nas etapas precedentes, os 64 sinais processados pelo *EEGLab* passam a variar entre 39 e 63 canais (linhas) e 25021 a 81921 colunas, formando sinais bidimensionais retangulares como produto. Com isso, inicia-se o processo de uniformização dos dados para posterior entrada na rede neural convolucional de aprendizagem. Para tanto, adiciona-se *padding* simétricos aos sinais EEG para padronização em 64 linhas ou canais e, em sequência, executa-se a partição dos mesmos em 1000 colunas para formação de imagens de dimensão  $64 \times 1000$ . Esta partição aumenta a quantidade de amostras para a etapa de treinamento da rede, resultando em 2079 imagens para a classe TEA e 2079 para TD, quando pré-processado a partir da taxa de amostragem original de 512 Hz. Finalmente, concatena-se todos os sinais em um único *array 3D* de dimensão  $64 \times 1000 \times 4158$  e produz-se um vetor de rótulos  $4158 \times 1$  para treinamento e classificação, onde a primeira metade assume valor binário 0 e a segunda metade, 1, referenciando-se aos sinais TEA e TD, respectivamente. Salienta-se que a quantidade de amostras para a fase de treinamento da CNN varia de acordo com a taxa de amostragem escolhida, isto é, para a frequência de amostragem de 256 Hz, obtém-se um *array 3D* de dimensão  $64 \times 1000 \times 2020$  e um *array 3D*  $64 \times 1000 \times 1002$  para

frequências de 128 Hz, com vetores de rótulos proporcionais à quantidade de amostras.

### C. Classificação

Para classificação (veja Figura 2), utiliza-se a biblioteca de rede neural de código aberto *Keras* [31], em *Python*. O carregamento e a partição de dados são etapas comuns aos dois modelos base de classificação abordados. Primeiramente, importa-se a base de dados em formato *.mat* pré-processada no *Matlab*, composta por uma matriz tridimensional  $X$  e um vetor de rótulos unidimensional  $Y$ . Após isso, reordena-se as constantes através da função *reshape* levando a quantidade de amostras para a primeira posição matricial, conforme exigem as funções de partição de dados e treinamento da rede. Em sequência, define-se como dimensão de entrada a constante *input\_s*, de dimensão  $64 \times 1000 \times 1$ , referente às linhas, colunas e quantidade de canais da imagem (imagem em escala de cinza), respectivamente. Por intermédio da função *train\_test\_split*, realiza-se a divisão da base de dados em 70% para treinamento, 15% para validação e 15% para testes. Por não haver função que divida a base em três partes para inclusão de percentual para validação, a função *train\_test\_split* foi utilizada duas vezes em sequência: primeiro para divisão em blocos de treinamento (70%) e validação/teste (30%), depois para divisão do segundo bloco efetivamente em teste (15%) e validação (15%). Todas as partições de treinamento, teste e validação do vetor de rótulos  $Y$  foram convertidas em categoria binária.

### D. Arquitetura CNN

A arquitetura da CNN proposta possui 17 camadas. A camada de entrada recebe os dados padronizados em  $64 \times 1000 \times 1$  para  $n$  amostras disponíveis, seguida pelas camadas: convolução  $2D$ , a qual foi projetada neste trabalho para manter a dimensão de entrada e aumentar ou diminuir a quantidade de canais; função de ativação *leakyRelu*, que executa uma operação de limite não linear em que qualquer valor de entrada menor que zero é multiplicado por um fator de escala fixo igual a 0,1 e; *maxpooling*, o qual simplifica as informações da camada anterior reduzindo sua dimensionalidade a partir dos valores máximos em uma determinada região. O conjunto das três últimas camadas (convolução  $2D$ , *leakyRelu* e *maxpooling*) é repetido igualmente por mais três vezes, apenas com alteração na quantidade de canais de convolução. Depois, finaliza-se com a camada *GlobalAveragePooling2D*,

para geração de um mapa de recursos para cada categoria correspondente da tarefa de classificação. Depois, uma camada densa de 128 neurônios, seguida por outra função de ativação *leakyRelu* e, finalmente, uma camada densa de 2 neurônios com função de ativação *sigmoid* para classificação binária.

Utiliza-se para o treinamento da CNN proposta o otimizador *Adam* (taxa de aprendizagem de 0,001), que é um método de descida de gradiente estocástico baseado na estimativa adaptativa de momentos de primeira e segunda ordem, usado em substituição ao procedimento estocástico clássico de gradiente descendente para atualizar pesos de rede de forma interativa, com base em dados de treinamento. Em conjunto, utiliza-se a função de custo *categorical\_crossentropy* para o modelo de classificação multiclasse onde há dois ou mais rótulos de saída. Alternativamente, neste trabalho foram utilizados nos experimentos outros modelos de otimizadores, como, *stochastic gradient descent* (SGD), *adaptive gradient algorithm* (AdaGrad) e *root mean square propagation* (RMSProp).

### E. Arquitetura RNN (LSTM)

A arquitetura de RNN escolhida para contrastar com o método anteriormente explanado foi a *long short-term memory* (LSTM) [32], conhecida por sua capacidade de aprender dependências de ordem em problemas de previsão de sequência. Tal como na CNN, a camada de entrada recebe os dados padronizados em  $64 \times 1000$  para  $n$  amostras disponíveis. As demais camadas são construídas a partir de pequenos blocos de camadas LSTM e *dropout*, experimentadas com diversos parâmetros de entrada na intenção de se encontrar o melhor modelo para a base de dados disponível. A camada densa de 2 neurônios com função de ativação *sigmoid* para classificação binária finaliza a arquitetura LSTM. Para o treinamento da rede, as seguintes configurações foram implementadas: otimizador *Adam*, com taxa de aprendizagem de 0,001 e função de custo *binary\_crossentropy*, usada recorrentemente em modelos de classificação binária.

### F. Outras arquiteturas

Além da arquitetura transcrita nos parágrafos anteriores, algumas modificações na rede convolucional foram empreendidas. Cita-se o uso da técnica de transferência de aprendizagem (*transfer learning*), a qual reutiliza o “conhecimento aprendido” de uma tarefa com muitos dados de treinamento rotulados disponíveis em uma nova tarefa que não possui tantos dados [33]. Neste trabalho, experimenta-se os modelos pré-treinados *ResNet-50*, *MobileNet* e *MobileNetV2*. Por se tratar de imagens com 3 canais de entrada (RGB), adiciona-se à frente uma camada de convolução 2D com 3 mapas de características para conversão dos dados de entrada padronizados de 1 canal, sem alteração da dimensão linha/coluna. Em outro experimento, a técnica de *autoencoder* foi explorada para investigação de possíveis ganhos com a compactação/extração de recursos de entrada e redução de ruídos a partir da adição de camadas densas com diferentes neurônios decrescentes.

### G. Resultados

Na Tabela I apresenta-se os resultados para diferentes classificadores. A 2D-CNN multicamadas apresentou os melhores resultados, especificamente alcançou 99,51% de acurácia de classificação, AuC de 99,95%, erro de 0,02 e 0,99 de precisão, *recall* e *f1-score*, utilizando sinais com frequência de amostragem de 512 Hz, função de custo *categorical\_crossentropy* e otimizador *Adam* com taxa de aprendizagem de 0,001. A rede LSTM foi outro classificador com excelentes resultados.

TABELA I  
SISTEMA DE CLASSIFICAÇÃO PROPOSTO PARA VÁRIOS CLASSIFICADORES.

Classificador	Acurácia	AuC	Erro	Precisão	Recall	F1-score
LSTM	97,77%	0,98	0,23	0,98	0,98	0,98
2D-CNN	<b>99,51%</b>	<b>0,99</b>	<b>0,02</b>	<b>0,99</b>	<b>0,99</b>	<b>0,99</b>
ResNet-50	84,48%	0,90	13,84	0,84	0,88	0,86
MobileNet	60,00%	0,64	51,52	0,57	0,67	0,61
MobileNetV2	67,50%	0,72	30,60	0,62	0,73	0,67
Autoencoder + 2D-CNN	82,27%	0,83	0,79	0,78	0,99	0,86
Milne <i>et al.</i> [27]	81,80%	-	-	-	-	-

Na Tabela I, pode-se verificar que os modelos pré-treinados *MobileNet* e *MobileNetV2* não ensejaram em ganhos expressivos nas principais métricas avaliadas, quando comparados aos outros classificadores. A rede *ResNet-50* apresentou desempenho satisfatório. É importante ressaltar que esses três classificadores (*MobileNet*, *MobileNetV2* e *ResNet-50*) foram treinados utilizando-se *transfer learning* a partir da *imagenet* [34, 35]. Apresenta-se a rede *autoencoder*, que alcançou resultados de 82,27% de acurácia na base de testes, utilizando duas camadas densas sequenciais de 6400 e 640 neurônios no treinamento do codificador, antes da rede 2D-CNN, o que sugere a perda de características importantes para o treinamento no processo da compactação. Para referência, os resultados de Milne *et al.* [27] são apresentados.

TABELA II  
COMPARAÇÃO COM ESTUDOS ANTERIORES DE DIAGNÓSTICO DE TEA

Autor	Base de dados (BD)	Método	Acurácia
Bhaskarachary <i>et al.</i> [20]	Child Mind Institute	Extra Trees	67,70 %
Kang <i>et al.</i> [16]	BD Kang <i>et al.</i> [16]	MRMR + SVM	85,44 %
Jayawardana <i>et al.</i> [17]	BD Jayawardana <i>et al.</i> [17]	1D-CNN	95,00 %
Ibrahim <i>et al.</i> [19]	Bonn, MIT, King A.	DWT + SE + kNN	94,62 %
Milne <i>et al.</i> [27]	BD Milne <i>et al.</i> [27]	DFA + ITC + MSE	81,80 %
<b>Sistema proposto</b>	BD Milne <i>et al.</i> [27]	2D-CNN	<b>99,51 %</b>

Na Tabela II apresenta-se uma comparação do melhor modelo proposto com outros estudos anteriores para o diagnóstico do TEA. Destaca-se que, com a mesma base de dados nos experimentos, nosso modelo superou em 17,71 pontos percentuais o melhor resultado de acurácia apresentado no trabalho de Milne *et al.* [27].

## IV. CONCLUSÃO

Neste trabalho, concebemos um sistema de classificação de sinais EEG para o diagnóstico TEA. Para classificação, utilizou-se uma CNN e uma RNN para sinais de EEG pré-processados, transformando-se sinais EEG unidimensionais em imagens bidimensionais a partir da concatenação de canais. Em relação a validação do sistema proposto, utilizou-se as métricas, acurácia, AuC, erro, precisão, *recall* e *f1-score*. Utilizou-se a base de dados de Milne *et al.*, da Universidade de *Sheffield* [28]. Em termos de resultados, verifica-se, a partir dos experimentos, que o melhor modelo proposto, 2D-CNN, pôde distinguir, com acurácia de 99,51%, indivíduos diagnosticados com TEA daqueles tipicamente desenvolvidos, seguido pelo modelo RNN (LSTM) que alcançou 97,77%. Outras bases de dados são necessárias para verificação da capacidade de generalização do modelo, bem como sua possível utilização em aprendizagem por transferência, dada a escassez de modelos *transfer learning* treinados com sinais EEG.

## AGRADECIMENTOS

Parte dos resultados desta pesquisa foram subsidiados por ENVISION Indústria de Produtos Eletrônicos LTDA nos termos da Lei Brasileira Federal No. 8.387/91 (SUFRAMA).

## REFERÊNCIAS

- [1] K. Najarian and R. Splinter. *Biomedical signal and image processing*. Taylor & Francis, 2012.
- [2] S. Sanei and J.A. Chambers. *EEG signal processing*. John Wiley & Sons, 2013.
- [3] W.C. Melo, E.B.L. Filho, and W.S.S. Silva Jr. SEMG signal compression based on two-dimensional techniques. *BioMedical Engineering OnLine*, 15:1–31, 04 2016.
- [4] Wheidima Melo, Eddie Filho, and Waldir Junior. Electromyographic signal compression through image encoders and preprocessing techniques. *Journal of Communication and Information Systems*, 31:188–197, 01 2016.
- [5] E.A. Clancy, E.L. Morin, and R. Merletti. Sampling, noise-reduction and amplitude estimation issues in surface electromyography. *Journal of Electromyography and Kinesiology*, 12(1):1–16, 2002.
- [6] N.M.N. Leite, E.T. Pereira, E.C. Gurjão, and L.R. Veloso. Deep convolutional autoencoder for EEG noise filtering. In *Proc. IEEE Int. Conf. on Bioinformatics and Biomedicine*, pages 2605–2612, 2018.
- [7] M. Roberto and F. Dario. *Surface Electromyography: Physiology, Engineering, and Applications*. John Wiley & Sons, 2016.
- [8] A. Gacek and W. Pedrycz. *ECG signal processing, classification and interpretation: a comprehensive framework of computational intelligence*. Springer Science & Business Media, 2011.
- [9] W.C. Melo, E.B.L. Filho, and W.S.S. Silva Jr. Electroencephalographic signal compression based on adaptive segmentation and video encoders. In *Proc. XXXV Simp. Brasileiro de Telecomunicações e Processamento de Sinais (SBt)*, pages 1–5, 09 2017.
- [10] W.S. Silva Jr, E.B.L. Filho, and W.C. Melo. Compressão de sinais eletromiográficos baseada em técnicas bidimensionais. In *Proc. XXXIII Simp. Brasileiro de Telecomunicações e Processamento de Sinais (SBt)*, pages 1–5, 01 2015.
- [11] P. Souza, W.S.S. Silva Jr, E.B.L. Filho, and L.C. Cordeiro. Compressão de sinais de eletrocardiograma utilizando técnicas de codificação distribuída. In *Proc. XXXVII Simp. Brasileiro de Telecomunicações e Processamento de Sinais (SBt)*, 01 2019.
- [12] C. Melissant, A. Ypma, E.E.E. Frietman, and C.J. Stam. A method for detection of alzheimer’s disease using ICA-enhanced EEG measurements. *Artificial Intelligence in Medicine*, 33(3):209–222, 2005.
- [13] K. Jiannan, H. Xiaoya, et al. The identification of children with autism spectrum disorder by SVM approach on EEG and eye-tracking data. *Computers in Biology and Medicine*, 120:103722, 2020.
- [14] J. Shen, X. Zhang, J. Li, Y. Li, L. Feng, C. Hu, Z. Ding, G. Wang, and B. Hu. Depression detection from electroencephalogram signals induced by affective auditory stimuli. In *Proc. Int. Conf. on Affective Computing and Intelligent Interaction*, pages 76–82, 2019.
- [15] Deborah Kerches. Novo relatório do CDC. <https://dradeborahkerches.com.br/novo-relatorio-aponta-1-a-cada-36-criancas-esta-no-espectro-do-autismo/>, 2023.
- [16] J. Kang, X. Han, J. Song, Z. Niu, and X. Li. The identification of children with autism spectrum disorder by SVM approach on EEG and eye-tracking data. *Computers in biology and medicine*, 120:103722, 2020.
- [17] Y. Jayawardana, M. Jaime, and Sa. Jayarathna. Analysis of temporal relationships between ASD and brain activity through EEG and machine learning. In *Proc. IEEE Int. Conf. on Information Reuse and Integration for Data Science (IRI)*, pages 151–158, 2019.
- [18] R.C.C. Cabral, G.C.C. Cabral, et al. Importance of early diagnosis and intervention in per-son with TEA for its inclusion in society. *Brazilian Journal of Health Review*, 5(2):7754–7765, 2022.
- [19] S. Ibrahim, R. Djemal, and A. Alsuwailem. Electroencephalography (EEG) signal processing for epilepsy and autism spectrum disorder diagnosis. *Biocybernetics and Biomedical Engineering*, 38(1):16–26, 2018.
- [20] C. Bhaskarachary, A.J. Najafabadi, and B. Godde. Machine learning supervised classification methodology for autism spectrum disorder based on resting-state electroencephalography (EEG) signals. In *Proc. IEEE Int. Conf. on Signal Processing in Medicine and Biology Symposium (SPMB)*, pages 1–4. IEEE, 2020.
- [21] Child Mind Institute Biobank. Dataset for autism spectrum disorder. <https://childmind.org/blog/healthy-brain-network-biobank-bringing-big-data-to-child-me/ntal-health>, Aaesso em 27/04/23, 2022.
- [22] Delorme and Makeig. EEGLAB wiki. <https://eeglab.org/>, 2013.
- [23] K. Gotham, S. Risi, A. Pickles, and C. Lord. The autism diagnostic observation schedule: revised algorithms for improved diagnostic validity. *Journal of autism and developmental disorders*, 37:613–627, 2007.
- [24] R.G. Andrzejak et al. Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state. *Physical Review E*, 64(6):061907, 2001.
- [25] A.L. Goldberger, L.A.N. Amaral, et al. Physiobank, physiotoolkit, and physionet: components of a new research resource for complex physiologic signals. *circulation*, 101(23):e215–e220, 2000.
- [26] M.J. Alhaddad, M.I. Kamel, H.M. Malibary, et al. Diagnosis autism by fisher linear discriminant analysis FLDA via EEG. *International Journal of Bio-Science and Bio-Technology*, 4(2):45–54, 2012.
- [27] E. Milne, R. Gomez, et al. Atypical EEG in autism spectrum disorder: Comparing a dimensional and a categorical approach. *Journal of abnormal psychology*, 128(5):442, 2019.
- [28] E. Milne, R. Gomez, A. Giannadou, and M. Jones. Atypical EEG in autism spectrum disorder: Comparing a dimensional and a categorical approach, 2022.
- [29] NHS. Health research authority. <https://www.hra.nhs.uk/>, 2022.
- [30] S. Sanei and J.A. Chambers. *EEG signal processing*. John Wiley & Sons, 2013.
- [31] F. Chollet et al. Keras. <https://keras.io/>, acesso em 27/04/2023, 2015.
- [32] A. Graves. Long short-term memory. *Supervised sequence labelling with recurrent neural networks*, pages 37–45, 2012.
- [33] Q. Yang, Y. Zhang, W. Dai, and S.J. Pan. *Transfer learning*. Cambridge University Press, 2020.
- [34] Stanford Vision Lab, Stanford University, Princeton University. Imagenet. Disponível em: <https://www.image-net.org/>, 2021.
- [35] M.A. Morid et al. A scoping review of transfer learning research on medical image analysis using imagenet. *Computers in biology and medicine*, 128:104115, 2021.