

**UNIVERSIDADE FEDERAL DE JUIZ DE FORA  
FACULDADE DE ENGENHARIA E INSTITUTO DE CIÊNCIAS EXATAS  
BACHARELADO EM ENGENHARIA COMPUTACIONAL**

**Davi Esteves dos Santos**

**Módulo de Atenção Residual no EEGNet para Interfaces Cérebro-Máquina**

Juiz de Fora

2026

Esteves dos Santos, Davi.

Módulo de Atenção Residual no EEGNet para Interfaces Cérebro-Máquina / Davi Esteves dos Santos. - 2026.

38 f.

Orientador: Heder Bernardino

Coorientador: Gabriel Henrique de Souza

Trabalho de Conclusão de Curso (Bacharelado) - Universidade Federal de Juiz de Fora, Faculdade de Engenharia e Instituto de Ciências Exatas. Bacharelado em Engenharia Computacional, 2026.

1. Interface Humano-Computador. 2. Imaginação Motora. 3. Redes Neurais Convolucionais. 4. Mecanismo de Atenção. 5. Eletroencefalograma. I. Bernardino, Heder, orient. II. de Souza, Gabriel Henrique, coorient. III. Título.

Davi Esteves dos Santos

**Módulo de Atenção Residual no EEGNet para Interfaces Cérebro-Máquina**

Trabalho de Conclusão de Curso apresentado ao corpo docente do curso de graduação em Engenharia Computacional da Faculdade de Engenharia e Instituto de Ciências Exatas da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do grau de Bacharel em Engenharia Computacional.

Orientador: Prof. D.Sc. Heder Bernardino

Coorientador: Prof. D.Sc. Gabriel Henrique de Souza

Juiz de Fora

2026

Davi Esteves dos Santos

**Módulo de Atenção Residual no EEGNet para Interfaces Cérebro-Máquina**

Trabalho de Conclusão de Curso apresentado ao corpo docente do curso de graduação em Engenharia Computacional da Faculdade de Engenharia e Instituto de Ciências Exatas da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do grau de Bacharel em Engenharia Computacional.

Aprovado em 20 de janeiro de 2026.

BANCA EXAMINADORA

---

Prof. D.Sc. Heder Bernardino - Orientador  
Universidade Federal de Juiz de Fora

---

Prof. D.Sc. Gabriel Henrique de Souza - Coorientador  
Universidade Federal de Juiz de Fora

---

Prof. D.Sc. Jairo Francisco de Souza  
Universidade Federal de Juiz de Fora

---

Prof. D.Sc. Aleksander Yacovenco  
Universidade Federal de Juiz de Fora

## AGRADECIMENTOS

Agraço o apoio fornecido pela CAPES, CNPq, FAPEMIG, FAPESP, UFJF e OpenBCI.

Agradeço ao professor Heder Bernardino pela orientação e aos coautores Gabriel Henrique de Souza, Alex Borges Vieira e Luciana Paixão Motta pela colaboração fundamental neste trabalho.

## RESUMO

*Brain-computer interfaces* (BCI) permitem que o cérebro se comunique com dispositivos eletrônicos. Em relação aos paradigmas de BCI, o *Motor Imagery* (MI) utiliza sinais cerebrais para decodificar um movimento imaginado. No entanto, fazer essa decodificação é difícil dada a baixa relação sinal-ruído. Normalmente, as principais etapas nos modelos de BCI são pré-processamento, extração de características e classificação. Nos últimos anos, *Convolutional Neural Networks* (CNNs) têm ganhado relevância em várias áreas da ciência devido às suas capacidades de extração de características, invariância à translação e compartilhamento de parâmetros. Outra forma mais recente de extração de características é o uso de mecanismos de atenção, que são camadas de redes neurais baseadas na atenção humana e têm a capacidade de destacar características importantes. Uma variação do mecanismo de atenção é o *Convolutional Block Attention Module* (CBAM), que combina a estrutura da CNN com o mecanismo de atenção. Neste trabalho, propomos um novo modelo que une a arquitetura principal do EEGNet, uma CNN compacta amplamente utilizada na literatura, com o CBAM e conexões residuais. As conexões residuais foram introduzidas para reduzir a degradação dos dados ao longo do modelo. Os resultados destacam a importância da conexão residual para o desempenho do modelo. O modelo proposto obteve um resultado kappa 6% melhor que o EEGNet com um p-valor menor que 0,01 no dataset 2a da BCI Competition IV, que é um dataset bem conhecido para MI. Além disso, a proposta foi melhor que o EEGNet para a maioria dos sujeitos testados e teve o melhor resultado no pior caso.

**Palavras-chave:** Interface Humano-Computador. Imaginação Motora. Redes Neurais Convolucionais. Mecanismo de Atenção. Eletroencefalograma.

## ABSTRACT

Brain-computer interfaces (BCI) allow for the brain to communicate with electronic devices. Concerning the BCI paradigms, motor imagery uses brain signals to decode an imagined movement. However, this is a hard task given the low signal-to-noise ratio. Usually, the main steps in BCI models are pre-processing, feature extraction, and classification. In recent years, Convolutional Neural Networks (CNNs) have been gaining relevance in several areas of science due to their feature extraction, translation invariance, and parameter sharing capabilities. Another, more recent way of feature extraction is using attention mechanisms, which are layers of neural networks based on human attention and have the ability to highlight important features. A variation of the attention mechanism is the Convolutional Block Attention Module, which combines the CNN structure with the attention mechanism. In this work, we propose a new model that joins the core architecture of EEGNet, a compact CNN widely used in the literature, with the Convolutional Block Attention Module and residual connections. The residual connections were introduced to lower data degradation throughout the model. The results highlight the residual connection's importance for the performance of the model. The proposed model obtained a kappa result 6% better than the EEGNet with a p-value less than 0.01 on BCI Competition IV dataset 2a, which is a well-known dataset for Motor Imagery. Furthermore, the proposal was better than EEGNet for most subjects and had the best-worst case.

**Keywords:** Brain-Computer Interface. Motor Imagery. Convolutional Neural Network. Attention Mechanism. Electroencephalogram.

## LISTA DE ILUSTRAÇÕES

4.1	Estrutura do EEGNet. A letra A significa função de ativação ELU. D significa dropout. D é atravessado por uma linha, pois não é usado no processo de teste. Adaptado de Lawhern <i>et al.</i> (2018). . . . .	17
4.2	<i>Convolutional Block Attention Module</i> . Adaptado de Woo <i>et al.</i> (2018). . . . .	19
5.1	Métodos propostos. O símbolo + significa soma elemento a elemento. C significa concatenação. . . . .	22
7.1	<i>Performance profile</i> usando a média do sujeito dos resultados kappa obtidos. . . . .	25
7.2	Matriz de confusão do modelo EEGRCBAM <sub>32</sub> , considerando todos os sujeitos agregados. . . . .	27
7.3	Matrizes de confusão do modelo EEGRCBAM <sub>32</sub> sujeito a sujeito. . . . .	28
7.4	Entropia de Confusão do modelo EEGRCBAM <sub>32</sub> , considerando todos os sujeitos agregados. . . . .	29
7.5	Entropia de confusão do modelo EEGRCBAM <sub>32</sub> sujeito a sujeito. . . . .	30
7.6	projeção das fronteiras de decisão do modelo EEGRCBAM <sub>32</sub> , considerando todos os sujeitos agregados. . . . .	32
7.7	projeção das fronteiras de decisão do modelo EEGRCBAM <sub>32</sub> sujeito a sujeito. . . . .	33

## LISTA DE TABELAS

- 7.1 Resultados do escore *kappa* para *5-fold stratified cross-validation*. O melhor valor para cada sujeito está em negrito. p-valores para cada método contra *EEGRCBAM*<sub>32</sub>: (1) p-valor < 0,05 e (2) p-valor < 0,01 . . . . . 24

## LISTA DE ABREVIACOES E SIGLAS

BCI	Interfaces Cerebro-Maquina (Brain-Computer Interface)
CBAM	Ateno em Blocos Convolucionais (Convolutional Block Attention Module)
CNN	Rede Neural Convolucionial (Convolutional Neural Network)
CSP	Padro Espacial Comum (Common Spatial Pattern)
EEG	Eletroencefalograma (Electroencephalogram)
ELU	Unidade Linear Exponencial (Exponential Linear Unit)
FBCSP	CSP com Banco de Filtros (Filter Bank CSP)
FPGA	Matriz de Portas Programaveis em Campo (Field Programmable Gate Array)
ICA	Anlise de Componentes Independentes (Independent Component Analysis)
LDA	Anlise Discriminante Linear (Linear Discriminant Analysis)
MI	Imaginao Motora (Motor Imagery)
MLP	Perceptron Multicamadas (Multilayer Perceptron)
SVM	Maquina de Vetores de Suporte (Support Vector Machine)

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>10</b>
<b>2</b>	<b>TRABALHOS RELACIONADOS.....</b>	<b>13</b>
<b>3</b>	<b>DATASET.....</b>	<b>15</b>
<b>4</b>	<b>MÉTODOS.....</b>	<b>16</b>
4.1	EEGNet .....	16
4.2	Convolutional Block Attention Module .....	18
<b>5</b>	<b>ABORDAGEM PROPOSTA.....</b>	<b>20</b>
<b>6</b>	<b>EXPERIMENTOS COMPUTACIONAIS .....</b>	<b>23</b>
<b>7</b>	<b>RESULTADOS E DISCUSSÃO .....</b>	<b>24</b>
<b>8</b>	<b>CONCLUSÃO.....</b>	<b>34</b>

## 1 INTRODUÇÃO

*Brain-Computer Interfaces* (BCIs) permitem a comunicação direta entre o cérebro e sistemas eletrônicos (Wolpaw *et al.*, 2002). Esses sistemas melhoram uma ampla gama de áreas, incluindo reabilitação, saúde, neurociência e entretenimento (Nicolas-Alonso e Gomez-Gil, 2012). Muitas funções cerebrais podem ser usadas em BCIs, como informação visual (Verbaarschot *et al.*, 2021) e *Motor Imagery* (MI) (Li *et al.*, 2020). Cada função cerebral tem um escopo de aplicações geralmente utilizadas, por exemplo, MI é usado na reabilitação motora pós-AVC (Cervera *et al.*, 2018) e no controle de próteses (Murphy *et al.*, 2017).

A abordagem padrão para BCI pode ser dividida em cinco etapas principais (De Souza *et al.*, 2019): (i) Aquisição de sinal: obtenção de sinais cerebrais; (ii) Pré-processamento: procedimentos de filtragem e remoção de ruído do sinal; (iii) Extração e seleção: procedimentos para capturar propriedades essenciais dos sinais; (iv) Classificação: atribuição de rótulos aos sinais a partir das características; e (v) Execução da Tarefa: o rótulo de classificação é usado pela aplicação. Cada uma dessas etapas requer abordagens distintas, dependendo do paradigma específico em investigação.

Várias abordagens estabelecidas podem ser utilizadas nas diferentes etapas das *pipelines* de BCI, como *Filter Bank* (Ang *et al.*, 2008) e *Independent Component Analysis* (ICA) (Winkler *et al.*, 2011) na etapa de pré-processamento para decomposição em bandas de frequência e remoção de artefatos, *Common Spatial Pattern* (CSP) (Blankertz *et al.*, 2008) na extração de características, visando maximizar a discriminação entre classes, e classificadores como *Linear Discriminant Analysis* (LDA) (Blankertz *et al.*, 2011) e *Support Vector Machine* (SVM) (Bruzzone e Marconcini, 2010).

O *Filter Bank Common Spatial Patterns* (FBCSP) (Ang *et al.*, 2008) é um exemplo de modelo que ilustra a integração das principais etapas da pipeline de BCI, combinando um *filter bank* para filtragem temporal, CSP para filtragem espacial, LogPower para extração de características e o classificador *Naive-Bayes Parzen-Window* (NBPW). Esse modelo evidencia como a escolha de métodos em cada etapa impacta diretamente o desempenho

do sistema.

Observa-se ainda que estudos sobre as propriedades dos sinais cerebrais desempenham um papel fundamental no desenvolvimento de *pipelines* de BCI mais eficientes. Paradigmas como o P300 exploram respostas cerebrais bem caracterizadas no domínio temporal, permitindo a definição mais precisa de estratégias de pré-processamento, extração de características e classificação.

As *Convolutional Neural Networks* (CNNs) surgiram como uma escolha popular para tarefas de *Motor Imagery* (MI) devido à sua capacidade de aprender padrões discriminativos diretamente dos dados (Hossain *et al.*, 2023). Nesse contexto, o modelo EEGNet (Lawhern *et al.*, 2018) destaca-se por integrar, em sua estrutura convolucional, princípios equivalentes às etapas do FBCSP, reduzindo a necessidade de engenharia manual de características. Além disso, seu tamanho compacto tem motivado diversos trabalhos voltados à implementação em *Field Programmable Gate Arrays* (FPGA), viabilizando aplicações embarcadas de BCI (Tsukahara *et al.*, 2020; Feng *et al.*, 2022).

Ao utilizar técnicas de redes neurais, como CNNs, pesquisadores podem melhorar o desempenho da BCI em algumas aplicações. O mecanismo de atenção (Bahdanau *et al.*, 2015) ganhou popularidade devido às suas capacidades poderosas, especialmente na estrutura do *transformer* (Vaswani *et al.*, 2017). O mecanismo de atenção permite que a rede se concentre em características relevantes ou regiões de interesse dentro dos dados de entrada, melhorando sua capacidade de capturar informações importantes (Vaswani *et al.*, 2017). Uma variante muito bem-sucedida do mecanismo de atenção é o Convolutional Block Attention Module (CBAM) (Woo *et al.*, 2018). Woo também propôs o uso de conexão residual (He *et al.*, 2016) em conjunto com o CBAM, permitindo que os modelos aumentem em profundidade e complexidade sem degradação.

Neste trabalho, é proposto uma nova abordagem de modelo baseada no EEGNet que usa CBAM e conexões residuais, visando aumentar a qualidade das soluções sem comprometer o pequeno tamanho do EEGNet. As conexões residuais em nosso modelo controlam a deterioração do sinal. Além disso, a proposta extrai novas características do sinal usando o mecanismo de atenção. Os resultados indicam que a combinação de

atenção e EEGNet melhora os modelos anteriores quando a conexão residual é incluída, sendo o melhor dos modelos testados, tendo o melhor pior caso e sendo o modelo mais robusto. Além disso, o modelo proposto mostrou ter melhores resultados e com menos variação entre diferentes sujeitos.

Este trabalho foi inspirado em um estudo previamente publicado de minha autoria (Dos Santos *et al.*, 2023), apresentado a seguir.

## 2 TRABALHOS RELACIONADOS

Esta seção apresenta uma revisão da literatura relevante que contextualiza e fundamenta as tecnologias adotadas neste trabalho.

Mecanismos de atenção em redes neurais têm suas raízes em modelos de linguagem natural e tradução automática. O conceito de atenção foi proposto pela primeira vez por Bahdanau *et al.* (2015). Alguns anos mais tarde, Vaswani *et al.* (2017) estenderam a aplicação de mecanismos de atenção à arquitetura *Transformer*.

*Transformers* alcançaram sucesso notável em vários domínios, incluindo processamento de linguagem natural (Vaswani *et al.*, 2017), visão computacional (Liu *et al.*, 2021b; Carion *et al.*, 2020; Dosovitskiy *et al.*, 2021), e reconhecimento de fala (Gulati *et al.*, 2020). O mecanismo de atenção em *Transformers* possibilitou que os modelos capturassem dependências de longo alcance de forma mais eficaz e melhorou sua capacidade de processar dados sequenciais.

Woo *et al.* Woo *et al.* (2018) introduziram o CBAM, aproveitando os pontos fortes das CNNs e mecanismos de atenção. O CBAM permite uma melhor extração de características localizadas, melhorando a capacidade da rede de capturar detalhes refinados e relações espaciais.

Com base nesses avanços, os mecanismos de atenção começaram a encontrar aplicações em BCIs. Zhang *et al.* (2018) estiveram entre os primeiros a aplicar mecanismos de atenção no domínio da BCI, demonstrando sua eficácia. Da mesma forma, Li *et al.* (2020) exploraram a aplicação de mecanismos de atenção em tarefas de MI, destacando seu potencial para melhorar o desempenho em paradigmas de BCI. Posteriormente, foram introduzidas redes neurais baseadas em atenção temporal e por canal para análise de MI (Liu *et al.*, 2022, 2021a, 2020). Zhang *et al.* (2022) propuseram uma abordagem de *filter bank* junto com mecanismos de atenção para melhorar a extração de características. Por fim, Wen *et al.* (2022) apresentaram uma arquitetura de rede de atenção 3D densamente conectada *cross-stage-partial*, que divide o fluxo de características entre estágios para reduzir redundância computacional. O uso de mecanismos de atenção em BCI já aponta para melhorias nos modelos, tanto em precisão quanto em robustez entre

os sujeitos. No entanto, mais experimentos ainda precisam ser realizados dado o número de possibilidades que a atenção permite.

Portanto, vários modelos emergiram como escolhas populares com o crescente uso de redes neurais na pesquisa em BCI. Entre esses modelos, *DeepConvNet* e *ShallowConvNet* propostos por Schirrneister *et al.* (2017) e EEGNet proposto por Lawhern *et al.* (2018) ganharam atenção significativa. Notavelmente, EEGNet se destaca como um modelo compacto que consegue manter níveis significativos de precisão. Seguindo isso, Yu *et al.* (2022) analisaram o impacto de uma camada CBAM com EEGNet.

A análise da literatura sobre o uso de redes neurais em BCI culminou no desenvolvimento do trabalho de referência (Dos Santos *et al.*, 2023), que este estudo busca expandir e aprofundar.

### 3 DATASET

O dataset BCI competition IV 2A (Tangermann *et al.*, 2012) foi selecionado devido ao seu amplo uso em pesquisas de MI. Os experimentos usaram uma configuração de 22 eletrodos, com uma taxa de amostragem de 250 Hz. O filtro passa-banda foi ajustado entre 0,5-100 Hz. Durante as tarefas de MI, cada tentativa durou 6 segundos seguidos por um curto tempo de pausa. Durante os 2 segundos iniciais, uma cruz de fixação é apresentada na tela, seguida por uma pista de 1,25 segundos. A pista se sobrepôs ao intervalo subsequente de 4 segundos onde os sujeitos realizaram o MI. Quatro classes de tarefas de MI foram consideradas: mão direita, mão esquerda, pés e língua. Um total de 9 sujeitos participaram de 2 sessões separadas, com cada sessão consistindo de 288 tentativas igualmente distribuídas entre as 4 classes.

## 4 MÉTODOS

Neste capítulo, apresentamos os modelos base fundamentais para nossa proposta EEGNet, CBAM e EEGRCBAM já mencionados no Capítulo 2.

### 4.1 EEGNET

EEGNet (Lawhern *et al.*, 2018) é uma CNN compacta, projetada especificamente para sinais de eletroencefalografia (EEG). Sua arquitetura foi inspirada em métodos clássicos de BCI, especialmente no algoritmo FBCSP, combinando filtragem temporal e espacial em um único modelo treinável. Uma de suas principais vantagens é a capacidade de aprender representações discriminativas com um número significativamente reduzido de parâmetros, tornando-o adequado para bases de dados pequenas e cenários com poucos exemplos por classe.

A estrutura do EEGNet é composta por dois blocos convolucionais principais, seguidos por uma etapa de classificação, conforme ilustrado na Figura 4.1. Cada bloco foi projetado para desempenhar um papel específico na extração hierárquica de características dos sinais de EEG.

No Bloco 1, as principais etapas são: (i) *Reshape*, que reorganiza a entrada original (canais  $\times$  tempo) em um formato compatível com convoluções 2D; (ii) *Convolução 2D temporal*, com tamanho de kernel (1, 64), onde o comprimento do kernel corresponde aproximadamente à metade da taxa de amostragem (128 Hz). Essa camada utiliza  $F_1$  filtros temporais e atua como um banco de filtros passa-banda aprendível, responsável por capturar padrões espectrais relevantes do sinal de EEG; (iii) *Batch normalization*, aplicada para estabilizar a distribuição das ativações, acelerar o treinamento e reduzir problemas de covariância interna; (iv) *DepthWiseConv2D*, com tamanho de kernel igual ao número de canais de EEG e  $D \times F_1$  filtros. Essa operação realiza convoluções espaciais independentes para cada filtro temporal, aprendendo combinações espaciais específicas dos canais de EEG dentro de cada banda de frequência, de forma análoga aos filtros espaciais do CSP; (v) *Batch normalization*, novamente aplicada para normalizar as ativações após a convolução espacial; (vi) *Função de ativação Exponential Linear Unit (ELU)*,

escolhida por sua capacidade de manter gradientes não nulos para entradas negativas, contribuindo para maior estabilidade no treinamento; (vii) *AveragePool2D* com tamanho 4, que reduz a resolução temporal, atuando como um mecanismo de suavização e redução de dimensionalidade; e (viii) *Dropout*, utilizado como técnica de regularização para mitigar *overfitting*, especialmente importante em bases de EEG com poucos exemplos.

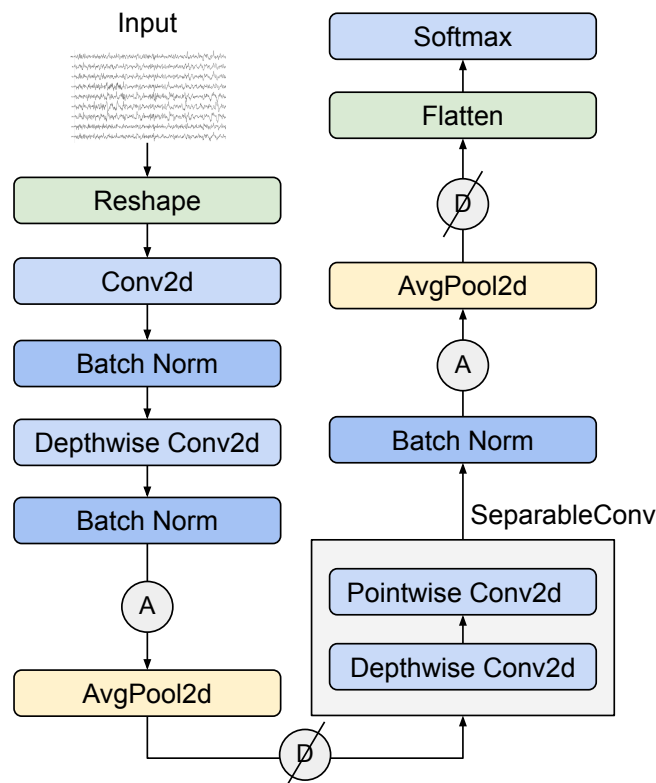


Figura 4.1: Estrutura do EEGNet. A letra A significa função de ativação ELU. D significa dropout. D é atravessado por uma linha, pois não é usado no processo de teste. Adaptado de Lawhern *et al.* (2018).

No Bloco 2, o objetivo é agregar informações temporais de maior escala e combinar os mapas de características aprendidos no bloco anterior: (i) *SeparableConv2D*, com tamanho de kernel 16 e  $F_2$  filtros. Essa operação consiste em uma convolução *depthwise* seguida de uma convolução ponto-a-ponto ( $1 \times 1$ ), permitindo capturar padrões temporais de maior duração com um custo computacional reduzido; (ii) *Batch normalization*, garantindo estabilidade das ativações; (iii) *Função de ativação ELU*; (iv) *AveragePool2D*

com tamanho (1, 8), promovendo uma nova redução da dimensão temporal e enfatizando padrões mais globais do sinal; (v) *Dropout*, reforçando a regularização do modelo; (vi) *Flatten*, que converte os mapas de características em um vetor unidimensional; e (vii) *Softmax*, responsável pela classificação final, produzindo probabilidades associadas a cada classe.

Uma característica importante do EEGNet é a ausência de camadas densas intermediárias antes da *Softmax*, o que reduz drasticamente o número de parâmetros e contribui para sua aplicabilidade em cenários com recursos limitados ou poucos dados.

## 4.2 CONVOLUTIONAL BLOCK ATTENTION MODULE

O CBAM (Woo *et al.*, 2018) é um mecanismo de atenção leve e genérico que pode ser integrado a arquiteturas CNN existentes, com o objetivo de refinar mapas de características ao enfatizar informações relevantes e suprimir ruídos. O CBAM combina a capacidade de extração local de padrões das CNNs com mecanismos globais de atenção, permitindo que a rede aprenda dinamicamente o que e onde focar durante o processo de inferência (Sicre e Jurie, 2015).

O CBAM é composto por dois módulos principais aplicados de forma sequencial: o módulo de atenção por canal e o módulo de atenção espacial.

O módulo de atenção por canal realiza as seguintes etapas: (i) *AvgPool* e *MaxPool* paralelos ao longo das dimensões espaciais, produzindo descritores globais que capturam estatísticas complementares das ativações; (ii) Ambas as saídas de *pooling* são passadas por um *Multilayer Perceptron (MLP)* compartilhado, composto por duas camadas totalmente conectadas com redução dimensional intermediária; (iii) As saídas do MLP são somadas elemento a elemento; (iv) Aplica-se uma função de ativação sigmoide, gerando uma máscara de atenção por canal com valores entre 0 e 1; e (v) A entrada original é multiplicada elemento a elemento por essa máscara, reforçando canais informativos e atenuando canais irrelevantes.

Em seguida, o módulo de atenção espacial foca em identificar regiões relevantes dentro do mapa de características: (i) *AvgPool* e *MaxPool* paralelos ao longo da dimensão dos

canais; (ii) Os mapas resultantes são concatenados e processados por uma convolução 2D, que aprende relações espaciais locais; (iii) Aplica-se uma função de ativação sigmoideal, produzindo uma máscara de atenção espacial; e (iv) A saída do módulo de atenção por canal é multiplicada elemento a elemento por essa máscara espacial, resultando em um mapa de características refinado tanto no domínio espacial quanto no domínio dos canais.

CBAM e seus módulos podem ser visualizados na Figura 4.2. Vale notar que, no contexto de BCI, as entradas são representadas como tensores 2D (canais  $\times$  tempo), apesar de o CBAM ter sido originalmente proposto para entradas 3D em visão computacional. Essa adaptação é viabilizada pelo uso de convoluções *depthwise* no EEGNet, que produzem mapas com profundidade unitária. Assim, os sinais de EEG podem ser tratados como mapas bidimensionais, permitindo a aplicação direta do CBAM sem perda conceitual.

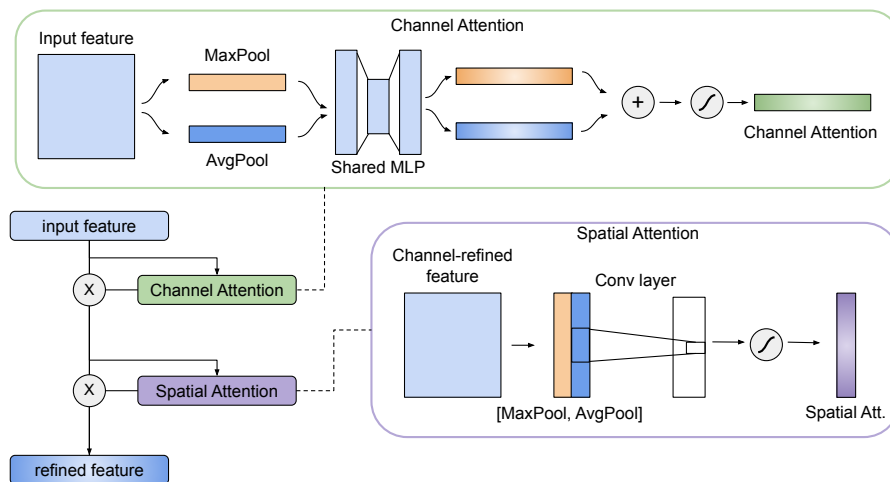


Figura 4.2: *Convolutional Block Attention Module*. Adaptado de Woo *et al.* (2018).

A integração do CBAM em arquiteturas como o EEGNet permite que o modelo destaque automaticamente padrões espectro-espaciais relevantes do EEG, potencialmente aumentando a capacidade discriminativa da rede sem introduzir um aumento significativo no número de parâmetros treináveis.

## 5 ABORDAGEM PROPOSTA

O *EEGNet-Residual-CBAM* (EEGRCBAM) proposto é uma variante do EEGNet original, construída sobre seus princípios centrais de compactação, eficiência computacional e adequação a cenários com poucos dados, características fundamentais em aplicações de BCI. O EEGNet foi originalmente concebido para aprender representações espaço-temporais discriminativas de sinais de EEG com um número reduzido de parâmetros, e o EEGRCBAM preserva essa filosofia ao introduzir mecanismos adicionais que aumentam a capacidade representacional do modelo sem comprometer significativamente sua leveza.

A arquitetura proposta é inspirada no EEGCBAM (Yu *et al.*, 2022), que introduz o módulo de atenção CBAM como um mecanismo para realçar automaticamente características relevantes extraídas pelo EEGNet. No entanto, o EEGRCBAM avança além dessa proposta ao incorporar explicitamente conexões residuais e uma estratégia de concatenação de características, com o objetivo de melhorar o fluxo de informações e evitar uma dependência excessiva dos mapas de atenção.

As principais diferenças do EEGRCBAM em relação ao EEGCBAM consistem, portanto, na adição de uma conexão residual ao redor do CBAM e na concatenação das saídas normalizadas do EEGNet-block e do bloco de atenção. Enquanto o EEGCBAM utiliza o CBAM como um refinador direto das características antes da classificação, o EEGRCBAM preserva explicitamente as representações originais aprendidas pelo EEGNet, permitindo que o classificador final explore simultaneamente informações refinadas e não refinadas.

A inclusão do CBAM tem como objetivo acentuar seletivamente as características mais informativas capturadas pelo EEGNet-block, que corresponde à arquitetura do EEGNet sem suas camadas finais de *flatten* e *softmax*. Nesse contexto, o CBAM atua como um mecanismo adaptativo que aprende a enfatizar padrões espectro-espaciais relevantes nos sinais de EEG, tanto ao longo da dimensão dos canais (atenção por canal) quanto ao longo da dimensão temporal (atenção espacial), contribuindo para a supressão de ruídos e características redundantes.

As conexões residuais (He *et al.*, 2016) desempenham um papel central na arquitetura proposta ao mitigar o problema de degradação observado em redes mais profundas. Ao permitir que a entrada de um bloco seja somada diretamente à sua saída, essas conexões facilitam o fluxo de gradientes durante o treinamento e reduzem a dificuldade de otimização associada a transformações excessivamente complexas. No EEGRCBAM, a conexão residual ao redor do CBAM garante que, caso o mecanismo de atenção não aprenda refinamentos úteis em determinadas situações, a informação original extraída pelo EEGNet-block ainda possa ser propagada de forma íntegra para as camadas subsequentes. Dessa forma, o CBAM passa a aprender correções residuais sobre as representações já existentes, em vez de substituí-las completamente.

Além disso, ao concatenar as características refinadas pelo CBAM com a saída original do EEGNet-block, a arquitetura amplia o espaço de representação disponível para a camada de classificação *softmax*. Essa estratégia assegura que a decisão final não dependa exclusivamente das máscaras de atenção aprendidas, mas também das características brutas de alto nível extraídas diretamente pelo EEGNet. Tal abordagem é particularmente relevante em sinais de EEG, nos quais padrões discriminativos podem ser sutis, distribuídos e altamente dependentes do contexto, tornando arriscada uma filtragem excessivamente agressiva por mecanismos de atenção.

Esses processos podem ser resumidos nas seguintes etapas sequenciais: (i) extração inicial de características espaço-temporais por meio do EEGNet-block; (ii) aplicação de *Layer Normalization* (Chollet, 2017) sobre as ativações resultantes, estabilizando sua distribuição; (iii) refinamento das características por meio do CBAM com conexão residual, permitindo aprendizado de atenção sem perda de informação; (iv) nova aplicação de *Layer Normalization* após o bloco de atenção, promovendo estabilidade adicional; (v) concatenação das saídas das duas camadas de normalização, combinando informações originais e refinadas; (vi) transformação dos mapas de características em um vetor unidimensional por meio de *flatten*; e (vii) classificação final via *Softmax*.

As camadas de *Layer Normalization* desempenham um papel fundamental na regularização do modelo. Diferentemente da *Batch Normalization*, a normalização em

camadas não depende do tamanho do mini-batch, o que a torna especialmente adequada para cenários de EEG, nos quais o número de amostras por classe é frequentemente limitado e o uso de batches pequenos é comum. Ao normalizar as ativações em nível de amostra, a *Layer Normalization* reduz a variabilidade interna da rede, estabiliza o processo de treinamento e contribui para uma melhor capacidade de generalização.

De forma geral, a combinação de atenção, conexões residuais, normalização e concatenação no EEGRCBAM busca equilibrar dois objetivos frequentemente conflitantes em BCI: manter a simplicidade e eficiência do EEGNet original, ao mesmo tempo em que se aumenta sua capacidade de modelar relações complexas e não lineares presentes nos sinais de EEG.

As estruturas do EEGRCBAM e do EEGCBAM podem ser visualizadas em mais detalhes na Figura 5.1, permitindo uma comparação direta entre as abordagens e evidenciando as modificações introduzidas pela arquitetura proposta.

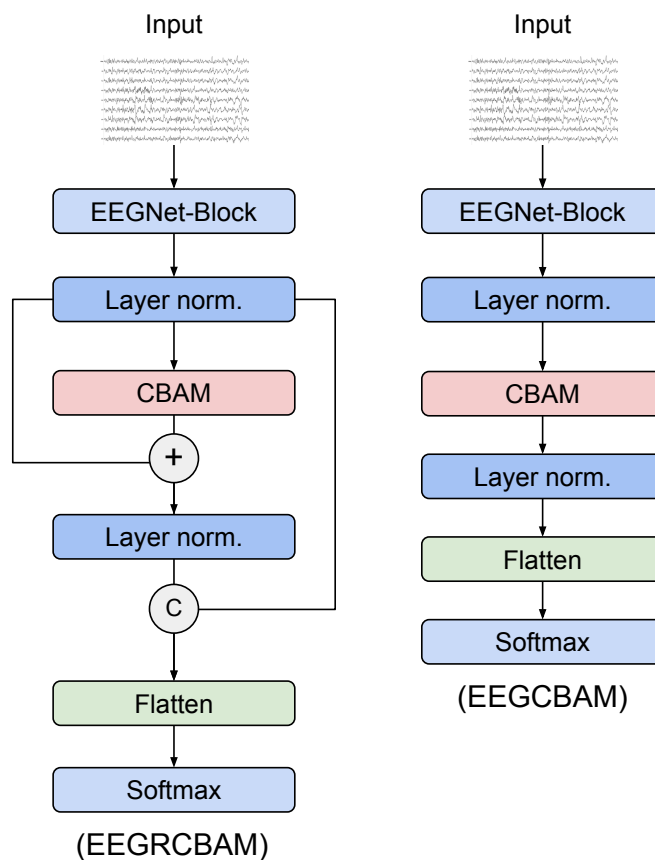


Figura 5.1: Métodos propostos. O símbolo + significa soma elemento a elemento. C significa concatenação.

## 6 EXPERIMENTOS COMPUTACIONAIS

O dataset da BCI Competition apresentado no Capítulo 3 foi escolhido para realizar os experimentos. Seu pré-processamento foi: redução da taxa de amostragem para 128 Hz e um filtro passa-banda de 4-40 Hz, seguindo a configuração experimental do EEGNet (Lawhern *et al.*, 2018).

Os modelos avaliados são EEGNet, EEGCBAM e EEGCRBAM. EEGNet e EEGCBAM foram escolhidos por serem redes que apresentam bons resultados para MI e têm tamanhos semelhantes ao modelo proposto.

Os tamanhos de *kernel* temporal de 32 e 64 foram escolhidos, pois ambos foram usados em (Lawhern *et al.*, 2018). Definimos o modelo com tamanho de *kernel* igual a 32, 64 como  $(\cdot)_{32}$  e  $(\cdot)_{64}$ .

A implementação e o treinamento foram realizados usando o *framework* PyTorch (Paszke *et al.*, 2019). Um *batch size* de 64 foi usado, pois esse valor é amplamente adotado na literatura (Keskar *et al.*, 2017) e 1000 iterações, com um *learning rate* de  $9 \times 10^{-4}$ . Testamos e treinamos o modelo para cada sujeito usando ambas as sessões e *5-fold stratified cross-validation*. Para treinamento e teste, os dados foram definidos de 0,5 a 2,5 segundos após a pista, como usado em (Lawhern *et al.*, 2018). O procedimento de treinamento empregou a função de perda de *cross-entropy* e o otimizador Adam. Para teste de hipóteses estatísticas, foi usado o teste de Wilcoxon. Os códigos e resultados estão disponíveis publicamente em <https://github.com/Davi-Esteves-dos-Santos/EEGRCBAM>.

## 7 RESULTADOS E DISCUSSÃO

A Tabela 7.1 apresenta os valores kappa obtidos para os modelos testados. O kappa foi escolhido por ser usado como métrica de desempenho na BCI Competition IV 2a.

Tabela 7.1: Resultados do escore *kappa* para *5-fold stratified cross-validation*. O melhor valor para cada sujeito está em negrito. p-valores para cada método contra *EEGRCBAM*<sub>32</sub>: (1) p-valor < 0,05 e (2) p-valor < 0,01

Sujeito	Método					
	EEGNet <sub>64</sub>	EEGNet <sub>32</sub>	EEGCBAM <sub>64</sub>	EEGCBAM <sub>32</sub>	EEGRCBAM <sub>64</sub>	EEGRCBAM <sub>32</sub>
1	<b>0.7061</b>	0.7039	0.6297	0.6645	0.6622	0.6993
2	0.2617	0.2986	0.2449	0.3285	0.2681	<b>0.3404</b>
3	0.8171	0.7847	0.7801	0.7731	<b>0.8357</b>	0.8239
4	0.3660	0.4330	0.3704	0.4238	<b>0.4537</b>	0.4236
5	<b>0.3775</b>	0.3405	0.2064	0.2245	0.2382	0.3471
6	0.3537	0.3166	0.3168	0.3609	<b>0.4210</b>	0.3720
7	0.6365	0.6110	0.6342	0.6900	0.7200	<b>0.7433</b>
8	0.7338	0.7291	0.7454	0.7476	0.7546	<b>0.7568</b>
9	0.7848	0.8124	0.8102	0.8101	0.8218	<b>0.8333</b>
<i>Average</i>	0.5597 (1)	0.5589 (2)	0.5265 (2)	0.5581 (2)	0.5750	<b>0.5933</b>

No geral, o EEGRCBAM<sub>32</sub> proposto alcançou os melhores resultados médios quando comparado às outras abordagens, superando o EEGNet<sub>64</sub> em kappa médio em 6%. Pode-se observar que o EEGRCBAM<sub>32</sub> é o único que obteve resultados estatisticamente diferentes daqueles encontrados por (1) EEGNet<sub>64</sub> considerando p-valor < 0.05, e (2) os outros métodos com p-valor < 0.01. Além disso, o EEGRCBAM<sub>32</sub> manteve um kappa médio maior ou igual para a maioria dos sujeitos. O EEGRCBAM<sub>64</sub> foi o segundo melhor método no geral.

EEGNet<sub>64</sub> e EEGCBAM<sub>64</sub> tiveram resultados semelhantes, como em (Yu *et al.*, 2022). Outra comparação notável é seu aumento relativamente modesto em tamanho, com EEGNet<sub>64</sub> tendo 1716 parâmetros, EEGRCBAM<sub>64</sub> com 3286 e EEGRCBAM<sub>32</sub> 3030. EEGRCBAM<sub>32</sub> é 76,6% maior que EEGNet<sub>64</sub>, mas ainda é conciso em comparação com outras abordagens populares da literatura, até 13 vezes menor que *ShallowConvNet*, e 50 vezes menor que *DeepConvNet*.

Para uma visão geral melhor dos modelos, usamos *performance profiles* (Dolan e Moré, 2002). Definimos o conjunto S de modelos  $s_i$ , e P como o conjunto de problemas  $p_j$  tal que  $j \in 1, \dots, n_p$ .  $t_{p,s}$  é o inverso do resultado médio do escore kappa de cada método e

problema, como sugerido por De Souza *et al.* (2019).

A razão de desempenho  $r_{p,s}$  é definida como:

$$r_{p,s} = \frac{t_{p,s}}{\min\{t_{p,s} : s \in S\}}, \quad (7.1)$$

Definindo a cardinalidade de um conjunto pelo seu valor absoluto, temos:

$$\rho_s(\tau) = \frac{1}{n_p} |\{p \in P : r_{p,s} \leq \tau\}|, \quad (7.2)$$

As três principais constatações mostrados nos *performance profiles* são: (i) o maior  $\rho(1)$  é observado na abordagem que obteve os melhores resultados; (ii) a abordagem mais robusta é aquela que atinge  $\rho(\tau) = 1$  com o menor tau; e (iii) a melhor abordagem geral possui a maior área sob as curvas do performance profile.

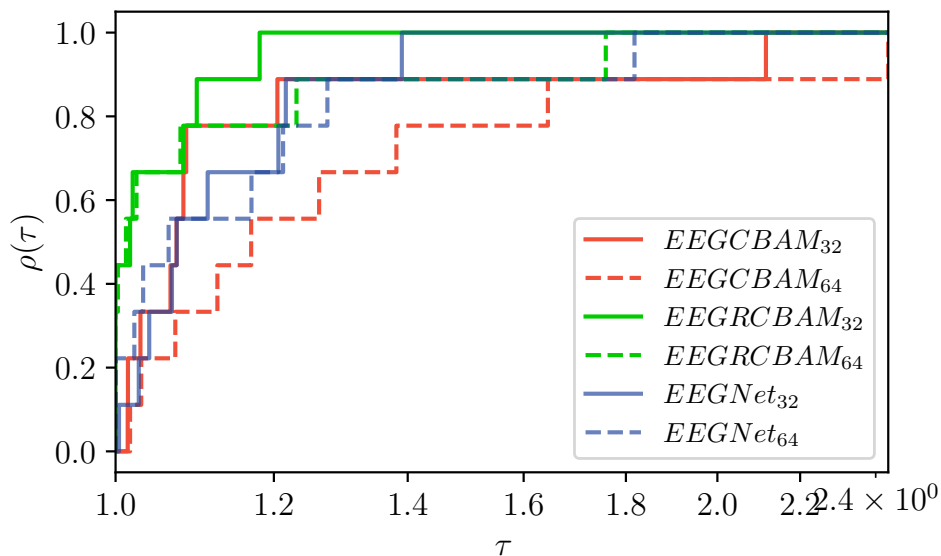


Figura 7.1: *Performance profile* usando a média do sujeito dos resultados kappa obtidos.

A Figura 7.1 mostra que EEGRCBAM<sub>32</sub> tem o melhor desempenho para a maioria dos sujeitos. Além disso, é o método mais robusto, pois é o primeiro a atingir  $\rho(\tau) = 1$ . Ademais, é a melhor abordagem, pois tem a maior área sob a curva. EEGNet<sub>32</sub> é o segundo método mais robusto, tendo resultados muito semelhantes às outras abordagens quando  $\tau < 1,2$ . A pior abordagem em relação à robustez é EEGCBAM<sub>64</sub>.

Além dessas análises globais, métricas adicionais são utilizadas para explorar de forma

mais aprofundada o comportamento do modelo proposto e seus resultados no conjunto de dados, permitindo uma investigação mais detalhada dos padrões de classificação aprendidos, além disso, utilizaremos essas métricas para análises gerais e sujeito a sujeito para avaliar a robustez do modelo, além da visão mais abstraída dos *performance profiles*.

A matriz de confusão (Ting, 2011) é utilizada para analisar a distribuição dos acertos e erros do modelo entre as diferentes classes da MI. Para um problema de classificação multi-classe com  $C$  classes, a matriz de confusão é definida como uma matriz quadrada  $\mathbf{A} \in \mathbb{R}^{C \times C}$ , na qual cada elemento  $a_{i,j}$  representa o número de amostras cuja classe verdadeira é  $i$  e cuja classe predita é  $j$ .

$$\mathbf{A} = \begin{bmatrix} a_{1,1} & a_{1,2} & \cdots & a_{1,C} \\ a_{2,1} & a_{2,2} & \cdots & a_{2,C} \\ \vdots & \vdots & \ddots & \vdots \\ a_{C,1} & a_{C,2} & \cdots & a_{C,C} \end{bmatrix}. \quad (7.3)$$

Formalmente, cada elemento da matriz de confusão é definido como:

$$a_{i,j} = |\{x : y(x) = i \wedge \hat{y}(x) = j\}|, \quad (7.4)$$

onde  $y(x)$  denota o rótulo verdadeiro associado à amostra  $x$ ,  $\hat{y}(x)$  representa a classe predita pelo classificador para essa amostra. Os elementos da diagonal principal da matriz ( $a_{i,i}$ ) correspondem às classificações corretas, enquanto os elementos fora da diagonal representam erros de classificação, indicando confusões entre pares específicos de classes.

No caso geral, a matriz evidencia padrões globais de confusão entre classes, permitindo identificar quais tarefas de MI apresentam maior sobreposição no espaço de características aprendido pelo modelo. Esses padrões refletem limitações estruturais da separabilidade entre classes e fornecem indícios sobre a dificuldade inerente do problema.

No caso sujeito a sujeito, a matriz de confusão revela variações individuais no comportamento do classificador, destacando diferenças na discriminabilidade das classes entre participantes. Essa análise é particularmente relevante em sistemas de BCI, nos quais a variabilidade inter-sujeitos é elevada, e permite avaliar a robustez do modelo

frente a diferentes padrões neurofisiológicos.

Os resultados da matriz de confusão são apresentados nas Figuras 7.2 para o caso geral e 7.3 sujeito a sujeito.

Geral

Classe Verdadeira	Mão Esquerda -	0.68	0.15	0.07	0.1
	Mão Direita -	0.14	0.72	0.05	0.09
	Pés -	0.09	0.07	0.63	0.21
	Língua -	0.06	0.07	0.12	0.75
		Mão Esquerda -	Mão Direita -	Pés -	Língua -
		Classe Predita			

Figura 7.2: Matriz de confusão do modelo EEGRCBAM<sub>32</sub>, considerando todos os sujeitos agregados.

A fim de complementar a análise na matriz de confusão, utiliza-se a entropia de confusão (Wei *et al.*, 2010) como métrica para quantificar o grau de incerteza associado às decisões do classificador. A entropia permite avaliar como os erros estão distribuídos entre as classes, fornecendo uma medida contínua do nível de ambiguidade do modelo em cenários multi-classe.

A entropia é calculada a partir da matriz de confusão normalizada por classe, interpretando cada linha como uma distribuição de probabilidade condicional das classes



Figura 7.3: Matrizes de confusão do modelo EEGRCBAM<sub>32</sub> sujeito a sujeito.

preditas dado o rótulo verdadeiro. Para uma classe  $i$ , a entropia é definida como:

$$H_i = - \sum_{j=1}^C p_{ij} \log p_{ij}, \quad (7.5)$$

onde  $C$  é o número de classes e  $p_{ij}$  representa a probabilidade de uma amostra da classe verdadeira  $i$  ser classificada como  $j$ .

Valores baixos de entropia indicam decisões consistentes e concentradas na diagonal da matriz de confusão, refletindo alta separabilidade entre classes. Por sua vez, valores elevados de entropia indicam maior dispersão das predições, caracterizando regiões de

sobreposição entre classes e maior incerteza do classificador.

Os resultados da entropia de confusão são apresentados nas Figuras 7.4 para o caso geral e 7.5 sujeito a sujeito.

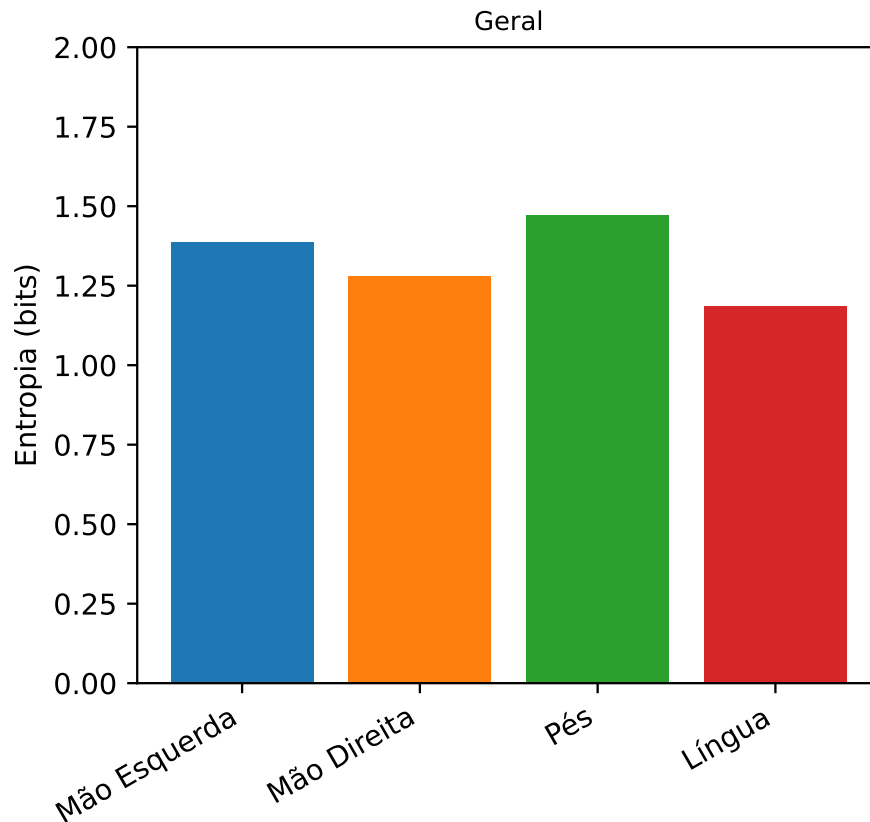


Figura 7.4: Entropia de Confusão do modelo EEGRCBAM<sub>32</sub>, considerando todos os sujeitos agregados.

A matriz de confusão geral indica que o EEGRCBAM<sub>32</sub> apresenta um padrão dominante de acertos ao longo da diagonal principal, evidenciando uma separação consistente entre as classes de MI. Essa observação é corroborada pela análise de entropia de confusão, que, em média, assume valores mais baixos para as classes com maior concentração de acertos, refletindo decisões mais estáveis do classificador. Ainda assim, a classe pés apresenta o desempenho global mais fraco, sendo frequentemente confundida com língua, o que se manifesta tanto em menores valores diagonais quanto em maiores níveis de entropia, indicando maior incerteza nas predições.

A análise sujeito a sujeito revela variações individuais relevantes nos padrões de classificação, consistentes entre ambas as métricas. Alguns sujeitos, como 3, 7,

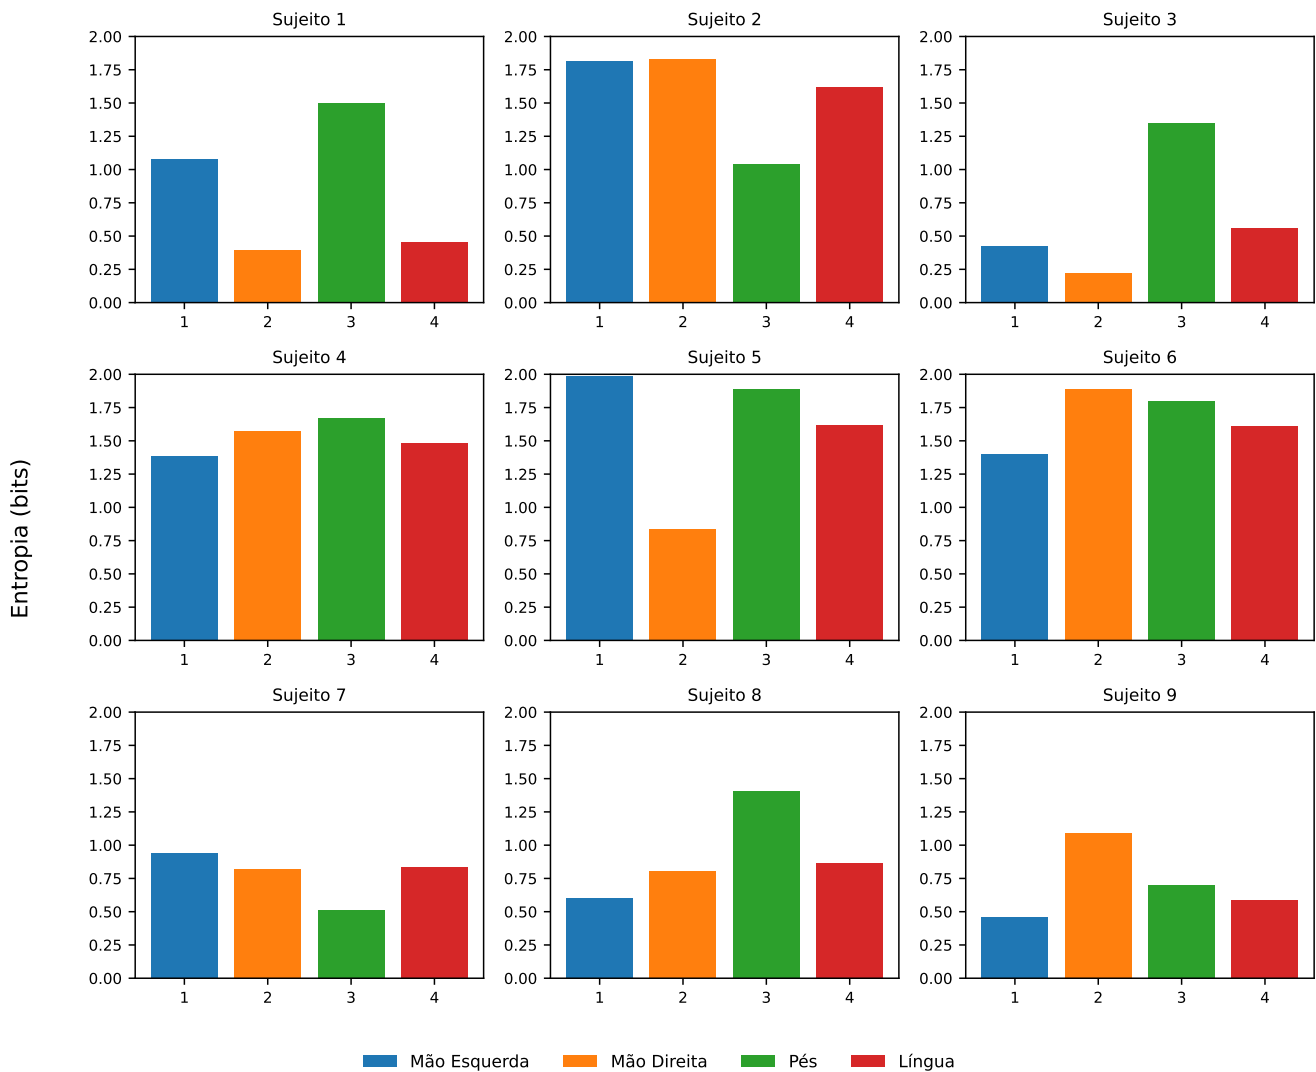


Figura 7.5: Entropia de confusão do modelo EEGRCBAM<sub>32</sub> sujeito a sujeito.

8 e 9, exibem matrizes fortemente diagonais acompanhadas de entropias reduzidas, caracterizando alta separabilidade entre classes. Em contraste, outros sujeitos apresentam confusões mais pronunciadas e entropias elevadas, refletindo maior ambigüidade decisória. No sujeito 2, apenas a classe pés é classificada de forma consistente, enquanto no sujeito 5 o desempenho está concentrado na classe mão direita. Já no sujeito 6, embora nenhuma classe atinja valores diagonais superiores a 0,70, também não se observam desempenhos inferiores a 0,38, resultando em entropias mais homogêneas e indicando uma distribuição mais equilibrada dos erros.

De forma recorrente, observa-se maior separabilidade da classe língua, associada a menores níveis de entropia, enquanto a classe pés tende a apresentar maior dispersão das

predições, especialmente em direção à língua. Esse comportamento pode refletir tanto dificuldades inerentes dos sujeitos na execução da tarefa de imaginação motora quanto limitações do modelo em capturar padrões discriminativos específicos dessa classe. Ainda assim, mesmo nos cenários de maior confusão, o EEGRCBAM<sub>32</sub> foi capaz de discriminar consistentemente ao menos uma ou duas classes por sujeito, reforçando que a elevada variabilidade inter-sujeitos permanece um dos principais desafios em sistemas BCI multi-classe.

Outra métrica é a projeção das fronteiras de decisão que serve como uma análise qualitativa do espaço de representação aprendido pela proposta, permitindo visualizar como as amostras de MI são organizadas após o processo de extração e discriminação de características. Essa visualização fornece uma perspectiva geométrica do comportamento do classificador no espaço latente, complementando as métricas quantitativas apresentadas anteriormente.

A partir dessas projeções, é possível obter diferentes tipos de conclusões sobre o modelo, tais como: (i) o grau de compactação intra-classe, refletindo a consistência das representações aprendidas; (ii) o nível de separação interclasse, associado à clareza das fronteiras de decisão; e (iii) a presença de regiões de sobreposição, que indicam áreas de maior ambiguidade e potencial fonte de erros de classificação.

Além disso, a análise das fronteiras de decisão permite avaliar como essas propriedades variam entre o caso agregado e o caso sujeito a sujeito, oferecendo indícios sobre a robustez do modelo e sobre o impacto da variabilidade inter-sujeitos no espaço de decisão aprendido.

Os resultados da projeção das fronteiras são apresentados nas Figuras 7.6 para o caso geral e 7.7 sujeito a sujeito.

É possível observar que, tanto na análise geral quanto na análise sujeito a sujeito, a classe língua apresenta o maior grau de compactação intra-classe, indicando uma representação latente mais consistente e bem definida. Em contraste, a classe pés exibe de forma recorrente uma sobreposição significativa com a classe língua, o que sugere uma proximidade estrutural no espaço de características aprendidas e ajuda a explicar as confusões observadas nas métricas quantitativas. Ademais, as projeções revelam uma

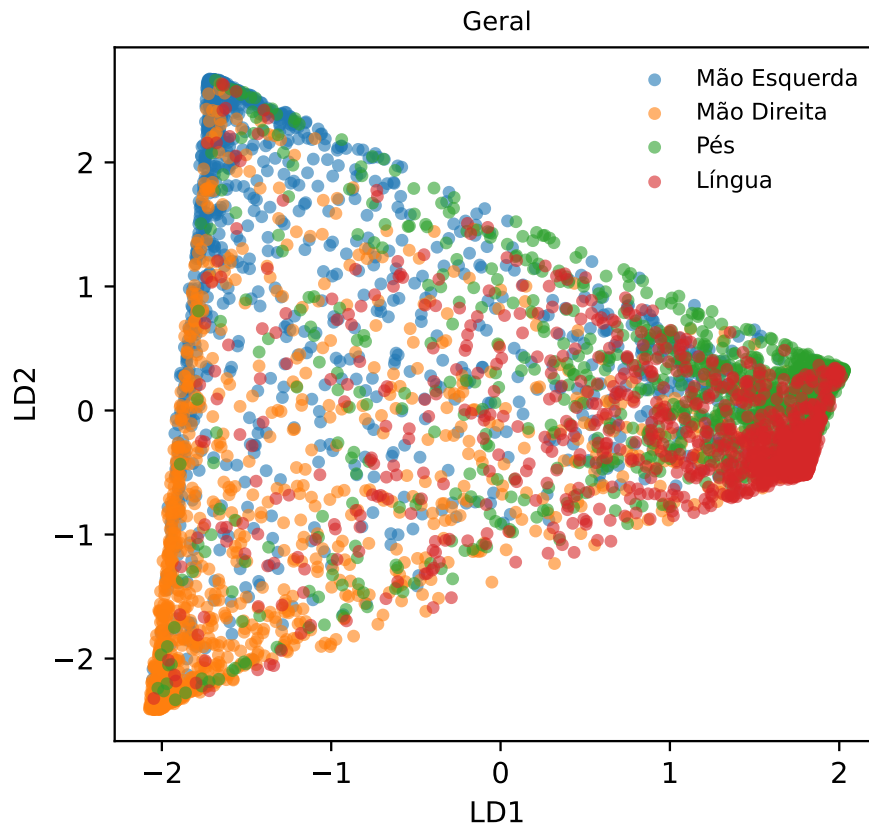


Figura 7.6: projeção das fronteiras de decisão do modelo EEGRCBAM<sub>32</sub>, considerando todos os sujeitos agregados.

proximidade espacial entre mão esquerda e mão direita, um padrão que não se manifesta de maneira tão evidente nas matrizes de confusão e nos valores de entropia, mas que se torna claro na análise geométrica do espaço latente.

Em conjunto, os resultados obtidos por meio do score kappa, dos performance profiles, das matrizes de confusão, da entropia de confusão e da projeção das fronteiras de decisão fornecem uma avaliação abrangente e coerente da robustez do EEGRCBAM<sub>32</sub>. Enquanto as métricas globais quantitativas demonstram superioridade estatística e consistência média entre sujeitos, as análises baseadas em confusão e entropia evidenciam estabilidade nas decisões do classificador e padrões recorrentes de separabilidade entre classes, mesmo diante da elevada variabilidade inter-sujeitos. Complementarmente, a projeção das fronteiras de decisão revela que essas propriedades se refletem no espaço latente aprendido, com regiões bem definidas de compactação intra-classe e separação interclasse, além de áreas localizadas de sobreposição que explicam os erros observados.

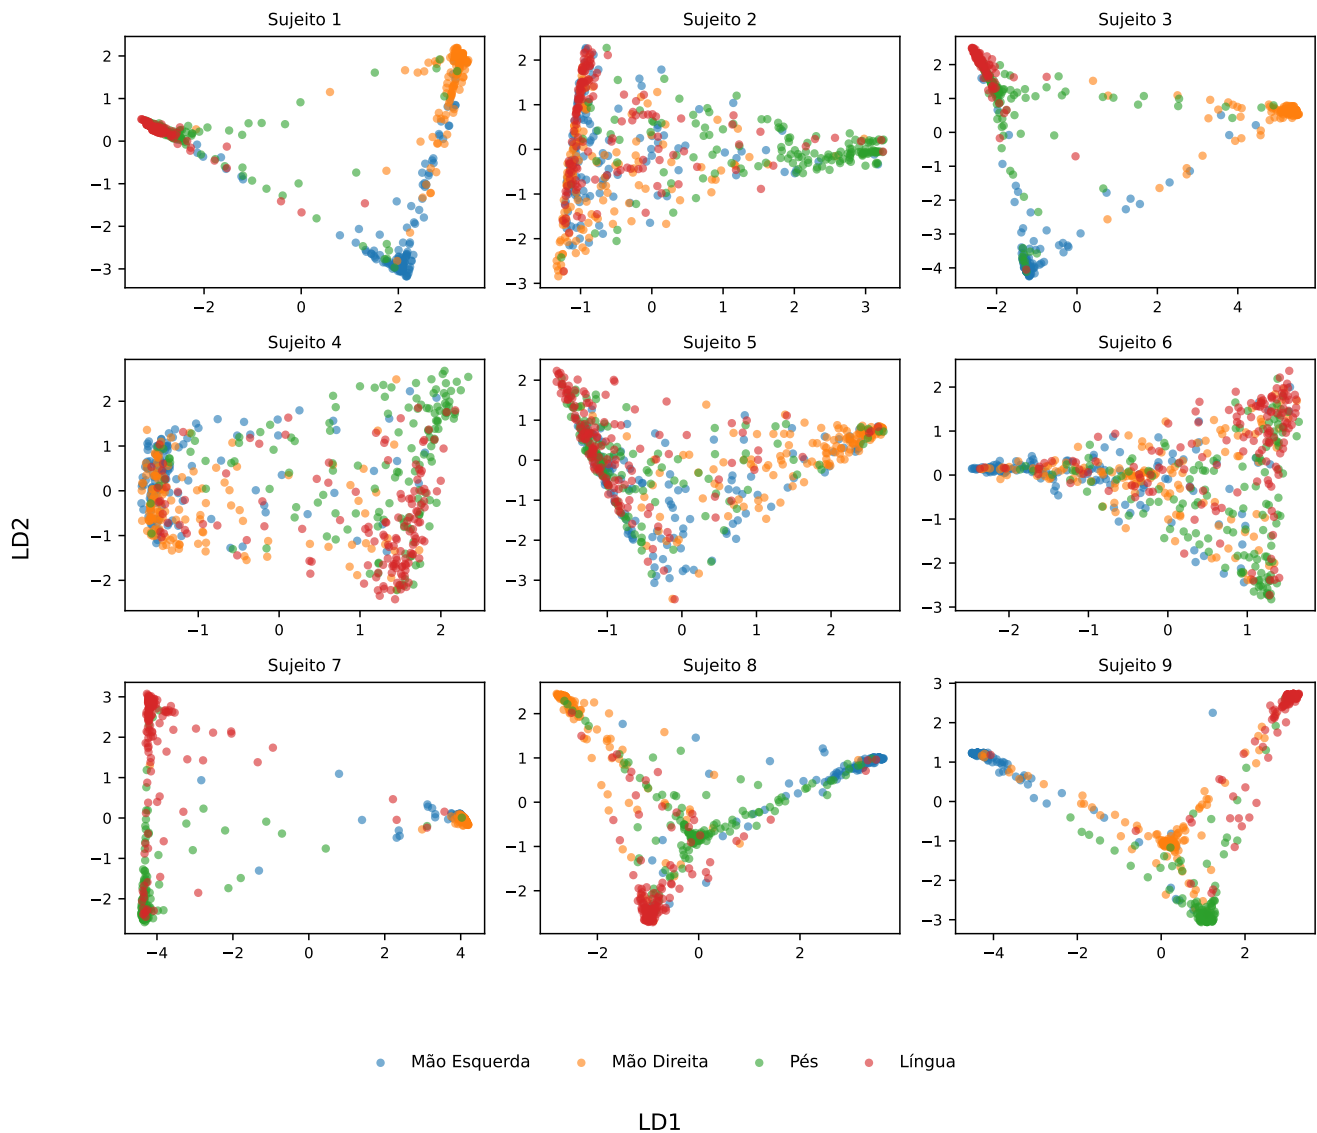


Figura 7.7: projeção das fronteiras de decisão do modelo EEGRCBAM<sub>32</sub> sujeito a sujeito.

Dessa forma, a convergência entre métricas quantitativas e qualitativas confirma que o EEGRCBAM32 não apenas apresenta desempenho superior, mas também mantém comportamento consistente e interpretável em diferentes níveis de análise, reforçando sua adequação para cenários reais de BCI multi-classe.

## 8 CONCLUSÃO

Com base no trabalho previamente publicado de minha autoria (Dos Santos *et al.*, 2023), são apresentadas a seguir as conclusões deste estudo.

BCIs têm uma ampla gama de aplicações, incluindo implementações em *Field Programmable Gate Arrays* (FPGA). Uma das ferramentas que viabilizam esse tipo de aplicação é a rede neural EEGNet, que é uma abordagem bem conhecida na literatura. Uma estratégia para aprimorar o EEGNet consiste no uso de mecanismos de atenção como o CBAM que destaca características globais com o mecanismo de atenção, mantendo-se compacto. No entanto, conexões residuais foram necessárias para manter algumas características ao longo do modelo e mitigar a degradação.

Neste artigo, é proposto o EEGRCBAM introduzindo duas novas etapas no EEGCBAM: (i) uma conexão residual no CBAM e (ii) uma concatenação do resultado das camadas normalizadas. O EEGRCBAM proposto foi avaliado para MI através do *dataset* BCICIV2a.

EEGRCBAM apresentou desempenho melhor ou similar ao EEGCBAM em todos os sujeitos avaliados e desempenho superior ao EEGNet na maioria dos sujeitos. Além disso, EEGRCBAM apresentou a maior robustez entre os sujeitos entre os modelos avaliados, tendo o melhor pior caso e apresentando um resultado consistente para todos os sujeitos sob a lente de diversas métricas. Esses resultados apontam para a importância da camada residual com CBAM em aplicações de BCI.

EEGNet e EEGCBAM não apresentaram mudança de desempenho significativa com mudança do tamanho do kernel, enquanto EEGCBAM e EEGRCBAM apresentaram melhor desempenho com *kernels* menores. Trabalhos futuros podem explorar análises mais aprofundadas de sensibilidade de parâmetros, bem como avaliações em diferentes *datasets*, visando validar a capacidade de generalização do modelo em múltiplos sujeitos.

EEGNet possui um grande número de trabalhos voltados à implementação em FPGA, o que se deve à sua arquitetura compacta quando comparada a outras CNNs na literatura. Assim como EEGNet, EEGRCBAM tem um baixo número de parâmetros e mantém uma precisão competente, aumentando ainda mais sua adequação para implementação prática,

mesmo em FPGA, destacando seu potencial para aplicações em tempo real e contextos com recursos limitados.

Por fim, uma limitação deste trabalho reside na necessidade de análises mais aprofundadas nas áreas de neurociência, a fim de responder a questões relacionadas à separabilidade ou proximidade entre as classes, bem como no letramento em BCI, para investigar discrepâncias significativas entre os resultados obtidos por diferentes sujeitos. Tais aspectos configuram direções naturais para trabalhos futuros, contribuindo para o desenvolvimento de modelos melhores no contexto de BCI.

## REFERÊNCIAS

- Ang, K., Chin, Z., Zhang, H., Guan, C., **Filter Bank Common Spatial Pattern (FBCSP) in brain-computer interface**. In: 2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence), 2008.
- Bahdanau, D., Cho, K., Bengio, Y., **Neural machine translation by jointly learning to align and translate**. In: International Conference on Learning Representations, 2015.
- Blankertz, B., Lemm, S., Treder, M., Haufe, S., Müller, K.-R., 2011. **Single-trial analysis and classification of ERP components - A tutorial**. NeuroImage.
- Blankertz, B., Tomioka, R., Lemm, S., Kawanabe, M., Müller, K.-R., 2008. **Optimizing spatial filters for robust EEG single-trial analysis**. IEEE Signal Processing Magazine.
- Bruzzone, L., Marconcini, M., 2010. **Domain adaptation problems: A DASVM classification technique and a circular validation strategy**. IEEE Transactions on Pattern Analysis and Machine Intelligence.
- Carion, N., Massa, F., Synnaeve, G., Usunier, N., Kirillov, A., Zagoruyko, S., 2020. **End-to-End Object Detection with Transformers**. Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics).
- Cervera, M., Soekadar, S., Ushiba, J., Millán, J., Liu, M., Birbaumer, N., Garipelli, G., 2018. **Brain-computer interfaces for post-stroke motor rehabilitation: a meta-analysis**. Annals of Clinical and Translational Neurology.
- Chollet, F., **Xception: Deep learning with depthwise separable convolutions**. In: 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017.
- De Souza, G. H., Vieira, A. B., Bernardino, H. S., Barbosa, H. J., **Differential evolution based spatial filter optimization for brain-computer interface**. In: Proceedings of the Genetic and Evolutionary Computation Conference, 2019.
- Dolan, E., Moré, J., 2002. **Benchmarking optimization software with performance profiles**. Mathematical Programming, Series B.
- Dos Santos, D. E., De Souza, G. H., Bernardino, H., Vieira, A. B., Motta, L. P., **Residual Attention Module on EEGN et for Brain-Computer Interface**. In: 2023 IEEE Symposium Series on Computational Intelligence (SSCI), 2023. pp. 58–63.
- Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., Dehghani, M., Minderer, M., Heigold, G., Gelly, S., Uszkoreit, J., Houlsby, N., **AN IMAGE IS WORTH 16X16 WORDS: TRANSFORMERS FOR IMAGE RECOGNITION AT SCALE**. In: International Conference on Learning Representations, 2021.
- Feng, L., Shan, H., Zhang, Y., Zhu, Z., 2022. **An Efficient Model-Compressed EEGNet Accelerator for Generalized Brain-Computer Interfaces With Near Sensor Intelligence**. IEEE Transactions on Biomedical Circuits and Systems.
- Gulati, A., Qin, J., Chiu, C.-C., Parmar, N., Zhang, Y., Yu, J., Han, W., Wang, S., Zhang, Z., Wu, Y., Pang, R., **Conformer: Convolution-augmented Transformer for Speech Recognition**. In: Proc. Interspeech 2020, 2020.
- He, K., Zhang, X., Ren, S., Sun, J., **Deep residual learning for image recognition**. In: 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016.

- Hossain, K., Islam, M., Hossain, S., Nijholt, A., Ahad, M., 2023. **Status of deep learning for EEG-based brain-computer interface applications**. *Frontiers in Computational Neuroscience*.
- Keskar, N. S., Mudigere, D., Nocedal, J., Smelyanskiy, M., Tang, P. T. P., 2017. **On Large-Batch Training for Deep Learning: Generalization Gap and Sharp Minima**.
- Lawhern, V. J., Solon, A. J., Waytowich, N. R., Gordon, S. M., Hung, C. P., Lance, B. J., 2018. **EEGNet: a compact convolutional neural network for EEG-based brain-computer interfaces**. *Journal of Neural Engineering*.
- Li, D., Xu, J., Wang, J., Fang, X., Ji, Y., 2020. **A Multi-Scale Fusion Convolutional Neural Network Based on Attention Mechanism for the Visualization Analysis of EEG Signals Decoding**. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*.
- Liu, X., Hui, Q., Xu, S., Wang, S., Na, R., Sun, Y., Chen, X., Zheng, D., **TACNet: Task-Aware Electroencephalogram Classification for Brain-Computer Interface through A Novel Temporal Attention Convolutional Network**. In: *Adjunct Proceedings of the 2021 ACM International Joint Conference on Pervasive and Ubiquitous Computing and Proceedings of the 2021 ACM International Symposium on Wearable Computers, 2021a*.
- Liu, X., Shen, Y., Liu, J., Yang, J., Xiong, P., Lin, F., 2020. **Parallel Spatial-Temporal Self-Attention CNN-Based Motor Imagery Classification for BCI**. *Frontiers in Neuroscience*.
- Liu, X., Shi, R., Hui, Q., Xu, S., Wang, S., Na, R., Sun, Y., Ding, W., Zheng, D., Chen, X., 2022. **TCACNet: Temporal and channel attention convolutional network for motor imagery classification of EEG-based BCI**. *Information Processing and Management*.
- Liu, Z., Lin, Y., Cao, Y., Hu, H., Wei, Y., Zhang, Z., Lin, S., Guo, B., **Swin Transformer: Hierarchical Vision Transformer using Shifted Windows**. In: *Proceedings of the IEEE/CVF international conference on computer vision, 2021b*.
- Murphy, D., Bai, O., Gorgey, A., Fox, J., Lovegreen, W., Burkhardt, B., Atri, R., Marquez, J., Li, Q., Fei, D.-Y., 2017. **Electroencephalogram-based brain-computer interface and lower-limb prosthesis control: A case study**. *Frontiers in Neurology*.
- Nicolas-Alonso, L., Gomez-Gil, J., 2012. **Brain computer interfaces, a review**. *Sensors*.
- Paszke, A., Gross, S., Massa, F., Lerer, A., Bradbury, J., Chanan, G., Killeen, T., Lin, Z., Gimelshein, N., Antiga, L., Desmaison, A., Köpf, A., Yang, E., DeVito, Z., Raison, M., Tejani, A., Chilamkurthy, S., Steiner, B., Fang, L., Bai, J., Chintala, S., 2019. **PyTorch: An Imperative Style, High-Performance Deep Learning Library**.
- Schirrmeister, R. T., Springenberg, J. T., Fiederer, L. D. J., Glasstetter, M., Eggensperger, K., Tangermann, M., Hutter, F., Burgard, W., Ball, T., 2017. **Deep learning with convolutional neural networks for EEG decoding and visualization**. *Human Brain Mapping*.
- Sicre, R., Jurie, F., 2015. **Discriminative part model for visual recognition**. *Computer Vision and Image Understanding*.

- Tangemann, M., Müller, K.-R., Aertsen, A., Birbaumer, N., Braun, C., Brunner, C., Leeb, R., Mehring, C., Miller, K., Müller-Putz, G., Nolte, G., Pfurtscheller, G., Preissl, H., Schalk, G., Schlögl, A., Vidaurre, C., Waldert, S., Blankertz, B., 2012. **Review of the BCI Competition IV**. *Frontiers in Neuroscience*.
- Ting, K. M., 2011. **Confusion Matrix**. In: Sammut, C., Webb, G. I. (Eds.), *Encyclopedia of Machine Learning*. Springer, Boston, MA, p. 209.
- Tsukahara, A., Anzai, Y., Tanaka, K., Homma, A., Uchikawa, Y., **A Design and Trial Production of EEGNet based EEG Pattern Recognition Processor using FPGA**. In: 2020 IEEE 8th R10 Humanitarian Technology Conference (R10-HTC), 2020.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A., Kaiser, L., Polosukhin, I., **Attention is all you need**. In: *Advances in neural information processing systems*, 2017.
- Verbaarschot, C., Tump, D., Lutu, A., Borhanazad, M., Thielen, J., van den Broek, P., Farquhar, J., Weikamp, J., Raaphorst, J., Groothuis, J., Desain, P., 2021. **A visual brain-computer interface as communication aid for patients with amyotrophic lateral sclerosis**. *Clinical Neurophysiology*.
- Wei, J.-M., Yuan, X.-J., Hu, Q.-H., Wang, S.-Q., 2010. **A novel measure for evaluating classifiers**. *Expert Systems with Applications* 37 (5), 3799–3809.
- Wen, Y., He, W., Zhang, Y., 2022. **A new attention-based 3D densely connected cross-stage-partial network for motor imagery classification in BCI**. *Journal of Neural Engineering*.
- Winkler, I., Haufe, S., Tangemann, M., 2011. **Automatic Classification of Artfactual ICA-Components for Artifact Removal in EEG Signals**. *Behavioral and Brain Functions*.
- Wolpaw, J., Birbaumer, N., McFarland, D., Pfurtscheller, G., Vaughan, T., 2002. **Brain-computer interfaces for communication and control**. *Clinical Neurophysiology*.
- Woo, S., Park, J., Lee, J.-Y., Kweon, I., 2018. **CBAM: Convolutional block attention module**. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*.
- Yu, H., Deng, Y., Yan, F., Guan, Z., Peng, F., **An Improved Schema of Brain-computer Interface Based on Motor Imagery with Eye Movement**. In: *Journal of Physics: Conference Series*, 2022.
- Zhang, D., Chen, K., Yao, L., Wang, S., **Ready for use: Subject-independent movement intention recognition via a convolutional attention model**. In: *CIKM 2018 - Proceedings of the 27th ACM International Conference on Information and Knowledge Management*, 2018.
- Zhang, Y., Qiu, S., Wei, W., Ma, X., He, H., 2022. **Dynamic Weighted Filter Bank Domain Adaptation for Motor Imagery Brain-Computer Interfaces**. *IEEE Transactions on Cognitive and Developmental Systems*.