

Inteligência Artificial Aplicada à Decodificação de Intenções Motoras

Desmistificando os Sinais Neurais da Imagética Motora (IM)

Isadora Stéfany Rezende Remigio Mesquita



UFG

UNIVERSIDADE
FEDERAL DE GOIÁS

UNIVERSIDADE FEDERAL DE GOIÁS (UFG)
INSTITUTO DE INFORMÁTICA (INF)

ISADORA STÉFANY REZENDE REMIGIO MESQUITA

**Inteligência Artificial Aplicada à Decodificação de Intenções
Motoras**

Desmistificando os Sinais Neurais da Imagética Motora (IM)

Goiânia
2025



UNIVERSIDADE FEDERAL DE GOIÁS
INSTITUTO DE INFORMÁTICA

TERMO DE CIÊNCIA E DE AUTORIZAÇÃO PARA DISPONIBILIZAR VERSÕES ELETRÔNICAS DE TRABALHO DE CONCLUSÃO DE CURSO DE GRADUAÇÃO NO REPOSITÓRIO INSTITUCIONAL DA UFG

Na qualidade de titular dos direitos de autor, autorizo a Universidade Federal de Goiás (UFG) a disponibilizar, gratuitamente, por meio do Repositório Institucional (RI/UFG), regulamentado pela Resolução CEPEC no 1240/2014, sem ressarcimento dos direitos autorais, de acordo com a Lei no 9.610/98, o documento conforme permissões assinaladas abaixo, para fins de leitura, impressão e/ou download, a título de divulgação da produção científica brasileira, a partir desta data.

O conteúdo dos Trabalhos de Conclusão dos Cursos de Graduação disponibilizado no RI/UFG é de responsabilidade exclusiva dos autores. Ao encaminhar(em) o produto final, o(s) autor(a)(es)(as) e o(a) orientador(a) firmam o compromisso de que o trabalho não contém nenhuma violação de quaisquer direitos autorais ou outro direito de terceiros.

1. Identificação do Trabalho de Conclusão de Curso de Graduação (TCCG)

Nome(s) completo(s) do(a)(s) autor(a)(es)(as): ISADORA STÉFANY REZENDE REMIGIO MESQUITA

Título do trabalho: Inteligência Artificial Aplicada à Decodificação de Intenções Motoras

Desmistificando os Sinais Neurais da Imagética Motora (IM)

2. Informações de acesso ao documento (este campo deve ser preenchido pelo orientador) Concorda com a liberação total do documento [X] SIM [] NÃO¹

[1] Neste caso o documento será embargado por até um ano a partir da data de defesa. Após esse período, a possível disponibilização ocorrerá apenas mediante: a) consulta ao(à)(s) autor(a)(es)(as) e ao(à) orientador(a); b) novo Termo de Ciência e de Autorização (TECA) assinado e inserido no arquivo do TCCG. O documento não será disponibilizado durante o período de embargo.

Casos de embargo:

- Solicitação de registro de patente;
- Submissão de artigo em revista científica;
- Publicação como capítulo de livro.

Obs.: Este termo deve ser assinado no SEI pelo orientador e pelo autor.



Documento assinado eletronicamente por **Isadora Stefany Rezende Remigio Mesquita, Discente**, em 14/01/2025, às 14:12, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Fernando Marques Federson, Professor do Magistério Superior**, em 15/01/2025, às 16:19, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **5089782** e o código CRC **CE7B03A1**.

Referência: Processo nº 23070.001589/2025-00

SEI nº 5089782

ISADORA STÉFANY REZENDE REMIGIO MESQUITA

**Inteligência Artificial Aplicada à Decodificação de Intenções
Motoras**

Desmistificando os Sinais Neurais da Imagética Motora (IM)

Relatório final de Trabalho de Conclusão de Curso, apresentado à Universidade Federal de Goiás, como parte das exigências para a obtenção do título de Bacharel em Inteligência Artificial.

Orientador: Prof. Dr. Fernando Marques Federson

Goiânia

2025

Ficha de identificação da obra elaborada pelo autor, através do Programa de Geração Automática do Sistema de Bibliotecas da UFG.

MESQUITA, ISADORA STÉFANY REZENDE REMIGIO
Inteligência Artificial Aplicada à Decodificação de Intenções Motoras
[manuscrito] : Desmistificando os Sinais Neurais da Imagética Motora
(IM) / ISADORA STÉFANY REZENDE REMIGIO MESQUITA. - 2025.
74 f.

Orientador: Prof. Dr. Fernando Marques Federson.
Trabalho de Conclusão de Curso (Graduação) - Universidade
Federal de Goiás, Instituto de Informática (INF), Inteligência
Artificial, Goiânia, 2025.

1. inteligência artificial. 2. interface cérebro-computador. 3.
imagética motora. I. Federson, Fernando Marques , orient. II. Título.

CDU 004

ISADORA STÉFANY REZENDE REMIGIO MESQUITA

**Inteligência Artificial Aplicada à Decodificação de Intenções
Motoras**

Desmistificando os Sinais Neurais da Imagética Motora (IM)

Relatório final de Trabalho de Conclusão de Curso, apresentado à Universidade Federal de Goiás, como parte das exigências para a obtenção do título de Bacharel em Inteligência Artificial.

Data da Aprovação: 17 de dezembro de 2024.



Prof. Dr. Fernando Marques Federson
Orientador (INF-UFG)



Prof. Dr. Aldo André Díaz Salazar
Coordenador de TCC do BIA (INF-UFG)



Prof. Dr. Anderson da Silva Soares
Coordenador do BIA (INF-UFG)



Prof. Dr. Iwens Gervasio Sene Junior
(INF-UFG)

ISADORA STÉFANY REZENDE REMIGIO MESQUITA

Inteligência Artificial Aplicada à Decodificação de Intenções Motoras

Desmistificando os Sinais Neurais da Imagética Motora (IM)

RESUMO

Este Relatório de Conclusão de Curso tem como objetivo reunir os resultados da minha jornada para me tornar um especialista em **Inteligência Artificial Aplicada a Sinais Neurais para Imagética Motora**. Uma ilustração e sua narrativa descrevem os períodos de trabalho. Os Apêndices contêm os Termos de Aceite de Entrega e os resultados obtidos durante cada período de trabalho.

Palavras-chave: inteligência artificial, modelos grandes de linguagem, geração automática de datasets.

ABSTRACT


This Course Completion Report aims to bring together the results of my journey to become an expert in **Artificial Intelligence Applied to Neural Signals for Motor Imagery**. An illustration and its narrative describe the work periods. The Appendices contain the Delivery Acceptance Terms and the results obtained during each work period.

Keywords: artificial intelligence, large language models, automatic dataset generation.

Goiânia
2025

Minha Jornada

Isadora Stéfany Rezende Remigio Mesquita



Especialista em: Inteligência Artificial Aplicada a Sinais
Neurais para Imagética Motora

Semanas 1-2

Fundamentos de Interface Cérebro-Computador (BCI)

Semana 3

Estudo de artigos com dados de eletroencefalografia (EEG) e exploração de Frameworks

Semanas 4-5

Estudo do Fluxo Geral de Processamento de Sinais de EEG

Semanas 5-6

Compreensão do modelo EEGNet e seu impacto na área

Semanas 7-8

Implementação de Classificadores de Intenção Motora utilizando o Fluxograma, os Frameworks e os algoritmos estudados

Semanas 9-10

Implementação de Classificadores de Intenção Motora utilizando Modelos Híbridos

MINHA JORNADA

Nome: Isadora Stéfany Rezende Remigio Mesquita

Especialidade: Inteligência Artificial Aplicada a Sinais Neurais para Imagética Motora

Objetivo deste documento

Durante o processo da disciplina Residência em IA¹, foram gerados diversos resultados na construção da minha especialização. A cada semana, um conjunto de resultados foi formalizado por um Termo de Aceite de Entrega e avaliado por uma banca, considerando o planejado e o realizado para o período. Este documento tem como objetivo descrever esses resultados obtidos, fazendo referência aos Termos de Aceite de Entrega e seus documentos associados.

Minha Jornada

Minha Jornada teve início ao descobrir a *International Conference on Applied Cognitive Computing* e decidir explorar áreas relacionadas à Neurociência Computacional, com o objetivo de definir minha especialização. No início dessa imersão, não estava claro como eu poderia desenvolver meus conhecimentos, considerando a amplitude e complexidade do tema, com o qual eu nunca havia tido contato. Para superar esse desafio, dediquei a **Stage um** à compreensão das origens da Neurociência Computacional, focando em sua história, fundamentos e principais categorias. Esse aprofundamento foi essencial para orientar meu interesse dentro dessa vasta área. Com uma direção mais clara, decidi explorar com mais profundidade a área de Interfaces Cérebro-Computador (BCI). Nesse contexto, realizei a leitura de um *review* abrangente que analisa os avanços dos últimos 50 anos nessa área, além de estudar diversos outros artigos e fontes relevantes. Assim que consolidei esse conhecimento inicial, direcionei a **Stage dois** ao entendimento da relação entre Inteligência Artificial e BCI, com um olhar voltado para as abordagens

¹ Dez semanas, entre setembro de 2024 e dezembro de 2024.

contemporâneas. Para isso, escolhi dois artigos recentes e assisti a uma palestra do pesquisador André Magno, que abordou a evolução da área de BCI e seu desenvolvimento na China. Inspirada pela palestra e acompanhando as publicações do pesquisador Luís Fernando da Silva Borges, descobri que a Tianjin University, na China, criou um curso de graduação em Interface Cérebro-Computador. Essa descoberta foi um marco na minha busca por frameworks da área, levando-me a conhecer o *META-BCI*, um framework desenvolvido por pesquisadores chineses que facilita o desenvolvimento de projetos em BCI, sendo acessível até para iniciantes. Além disso, explorei outros frameworks importantes, como o MNE e outros que ampliaram minha base de conhecimento e práticas na área. Nas **Semanas 1 e 2** de imersão, esse estudo aprofundado não apenas foi fundamental para direcionar minha escolha de especialização, mas também consolidou os fundamentos necessários para minha atuação em BCI. Os materiais relacionados a estas duas Semanas podem ser encontrados no **Apêndice 1**.

A partir da definição da área, foi possível, na **Semana 3**, dar continuidade na construção do conhecimento a respeito de abordagens que unem BCI e Inteligência Artificial. Por isso, segui com a leitura de outros artigos que contribuem com a área e focados em diversas aplicações. O meu objetivo era, também, construir um conhecimento amplo a respeito do assunto, para entender melhor como os sinais neurais eram processados e o que deveria ser levado em consideração em cada abordagem. Isso porque cada parte do cérebro é responsável por ações específicas em nosso corpo. Nesse sentido, me surpreendi com algumas abordagens, principalmente a abordagem adotada no artigo *Deep feature extraction from EEG signals using xception model for emotion classification*. Além disso, explorando o framework META-BCI, encontrei arquiteturas de redes que foram projetadas para lidar com dados EEG e suas complexidades, então iniciei o estudo da arquitetura da EEGNet por meio do artigo original, assim como a exploração de outros frameworks anotados (MNE, Vision, Braindecode...). Essa rede foi citada em alguns artigos para comparação de desempenho, quase sempre apresentando desempenho considerável. Um passo crucial nessa etapa foi a decisão sobre o tipo de dado com o qual eu iria trabalhar. Na primeira semana, explorei as diversas formas de coleta de sinais neurais e adquiri uma visão mais abrangente. No entanto, ao longo dos estudos subsequentes, percebi a necessidade de focar em um tipo de dado específico para minha especialização. Assim, optei por

trabalhar exclusivamente com dados de Eletroencefalograma (EEG), decisão que considero essencial para consolidar meu conhecimento e avançar na área. Os materiais relacionados a esta Semana podem ser encontrados no **Apêndice 2**.

Nas **Semanas 4 e 5**, aprofundei meu conhecimento sobre os diferentes tipos de EEG, analisando seus principais diferenciais, vantagens e desvantagens. Paralelamente, continuei o estudo da rede EEGNet, ampliando minha compreensão sobre sua arquitetura. Um artigo que chamou particularmente minha atenção foi *EEG Motor Imagery Decoding: A Framework for Comparative Analysis with Channel Attention Mechanisms*, devido à sua proposta de modificar a arquitetura que eu estava explorando. Por meio de sua implementação, pude perceber como os mecanismos de atenção podem contribuir significativamente para diversas abordagens, sejam elas voltadas para classificação ou não. Esses mecanismos permitem extrair informações essenciais para identificar as principais origens dos sinais nos dados recebidos, facilitando a seleção de *features*. Além disso, ao notar a ênfase de vários estudos na complexidade do processamento de dados EEG, estabeleci como novo objetivo desenvolver um conhecimento aprofundado o suficiente para dominar o pré-processamento desses sinais. Isso inclui a capacidade de processá-los com clareza e alinhamento a objetivos concretos. Com isso em mente, iniciei o mapeamento de diversas técnicas aplicáveis ao fluxo de processamento de sinais EEG voltado para classificação. Esse esforço foi motivado, em parte, pela abertura de uma competição na plataforma Kaggle promovida pelo Instituto Santos Dumont. Essa oportunidade me estimulou a submeter uma solução prática, consolidando os conhecimentos adquiridos até então e aplicando-os a um problema real. Os materiais relacionados a estas duas Semanas podem ser encontrados no **Apêndice 3**.

Nas **Semanas 5 e 6**, dediquei-me a reforçar o conhecimento adquirido sobre a arquitetura EEGNet e a dar continuidade ao estudo do fluxo geral de processamento de dados EEG. Após concluir as etapas teóricas, iniciei a parte prática. Utilizando os dados da competição do Kaggle, promovida pelo Instituto Santos Dumont, comecei a explorar a arquitetura e os frameworks de forma mais tangível. Minha primeira abordagem foi com o *META-BCI*, que oferece um modelo sem pesos, implementado no framework *Scorch*. Essa foi minha primeira experiência com o *Scorch*, possibilitada por essa oportunidade.

Paralelamente, procurei um modelo pré-treinado na biblioteca Hugging Face para realizar comparações. No entanto, ambas as implementações apresentaram resultados insatisfatórios e bastante similares. A partir da análise das *losses* de treino e validação, ficou evidente que os modelos não estavam aprendendo com os dados disponibilizados, independentemente do número de épocas treinadas. Os resultados permaneceram ruins, com a *loss* piorando progressivamente. Para o pré-processamento dos dados, apliquei as abordagens estudadas utilizando a biblioteca MNE, o que foi essencial para organizar os sinais de maneira estruturada. Também aprofundi meu conhecimento no Sistema Internacional 10-20, amplamente utilizado em abordagens BCI em todo o mundo. Esse sistema foi crucial para mapear os sinais EEG e compreender seu posicionamento no crânio, com base nos dados fornecidos pela competição. Para compreensão dos desafios e limitações, foi gerado um documento. Os materiais relacionados a estas duas Semanas podem ser encontrados no **Apêndice 4**.

Levando em consideração os desafios encontrados, as **Semanas 7 e 8** foram concentradas em encontrar problemas na implementação que estava sendo adotada e tentar outras abordagens que fossem capazes de solucionar a problemática. Para isso, foi revisto todo o fluxo de processamento de dados, bem como a seleção de canais (eletrodos) que estava sendo realizada para os dois casos. Ao estudar melhor a rede pré-treinada, selecionei os mesmos canais selecionados pelos autores para treinamento (anteriormente essa seleção estava ocorrendo por meio da implementação do ICA), mas contrariando as expectativas, não houve melhora no desempenho. Isso causou estranheza, dada a valorização da rede por pesquisadores da área. Por isso, decidi implementar outros classificadores, como SVM, a fim de compreender melhor como seria o desempenho deles nos dados propostos. Eles apresentaram um resultado melhor que a EEGNet, porém, ainda semelhante, o que me indicou que os dados ainda possuíam algum problema. A fim de compreender o que eu poderia estar fazendo diferente nos dados, estudei o artigo *Influência da Janela de Estimação no Desempenho de Classificação em Sistemas BCI-SSVEP*, pois eu sei que a janela tem influência em aplicações de áudio, mas gostaria de entender enxergar melhor esse cenário em aplicações BCI. Além disso, desde o início da minha Jornada, sempre ficou muito claro como é desafiador que existam dados nessa área, visto a sua complexidade de aquisição. Por isso, o artigo *Explorando os modelos de difusão em sistemas*

BCI-SSVEP me chamou atenção, e inclui ele nos estudos da stage. Por meio dele, são abordados modelos de difusão e como a geração de dados sintéticos têm impactado positivamente os resultados, contribuindo com generalização por meio de modelos generativos, como GANs. Por fim, ao final dessa semana, encontrei a problemática na minha abordagem, a qual de fato estava atrelada ao processamento de dados. Com receio de perder informações significativas, estava utilizando meus sinais de forma integral ou selecionando de forma indevida a parte interessante deles. Ao adotar interpolação, os resultados melhoraram significativamente em ambas as abordagens, apresentando um F1-Score entre 67% e 74%. No desafio proposto (classificação de intenção motora), os dados utilizados para metrificar são de pessoas que não tiveram seus dados utilizados no treinamento do modelo, o que nos indica que há uma boa generalização dado o tamanho do desafio de generalizar na área, sendo inclusive um dos principais problemas em abordagens BCI. Os materiais relacionados a estas duas Semanas podem ser encontrados no **Apêndice 5**.

Por fim, nas **Semanas 9 e 10**, fui em busca de explorar de forma prática soluções com modelos híbridos. Dito isso, me propus a implementar um artigo intitulado *Classificação de imagética motora baseada em EEG utilizando árvores de decisão*, o qual tem como objetivo realizar a classificação de imagética motora binária utilizando classificadores simples e rápidos. Nesse caso, foram experimentadas árvores de decisão, máquinas de vetor de suporte e redes bayesianas. Os dados utilizados nesse artigo são oriundos da Competition IV BCI 2b, no formato .gdf (formato universal para dados fisiológicos), os quais foram um desafio, isso porque a sua estrutura é muito diferente dos dados disponibilizados no Kaggle pelo Instituto Santos Dumont. Logo na primeira Semana, foram estudados e analisados diversos artigos, bem como evidenciados em um documento os desafios de implementação de cada um deles. Foi extremamente desafiador trabalhar com os dados .gdf, sendo necessária uma etapa de exploração para compreender a sua formatação. Na Semana seguinte, a implementação foi continuada, após averiguar diversas inconsistências no processamento dos dados, etapas as quais precisaram ser refeitas. Além disso, a utilização de um algoritmo de Busca Evolutiva com poucas informações de implementação também foram muito desafiadoras, dada a diversidade de possibilidades. É interessante pontuar que

os atributos pelos quais essa Busca Evolutiva Particle Swarm Optimization (PSO) são responsáveis, correspondem a 33 características distintas que são extraídas dos sinais. Os materiais relacionados a estas duas últimas Semanas podem ser encontrados no **Apêndice 6**.

Em função de tudo que vivi nesta Jornada, gostaria de deixar registrado que apesar de desafiadora, a área é incrível e me mostrou que apesar de árduo, o processo sempre traz recompensas inestimáveis ao olharmos para trás. Em muitos momentos, focamos no objetivo e esquecemos de olhar com carinho e com a real importância para todo o percurso a ser vivido. Pude crescer imensamente durante esse curto trajeto, e não somente tecnicamente, mas também como pessoa, em que a resiliência foi necessária Semana após Semana, mesmo fazendo algo que me agrada e possui meu interesse genuíno. Finalizo a minha Residência com a certeza de que iniciei algo que não terá fim, mas também com a segurança de que posso encarar qualquer outro desafio, pois eu conheço o caminho, basta saber se irei encarar meus desafios como Tales ou como Faraó.

APÊNDICE 1

Termo de Aceite de Entrega

Objetivo deste documento

Este documento faz parte do Processo da disciplina Residência em IA e tem como objetivo formalizar o aceite da entrega considerando o planejado e o realizado para o período.

Data da Reunião (“gate”) de aprovação: 19 de set. de 2024

Participantes da Entrega [matriculados em Residência em IA]:

Isadora Stéfany Rezende Remigio Mesquita

Entrega: [descrever a ENTREGA: requisitos e produtos gerados: links para textos, códigos, vídeos etc.]

Stage 1:

No meu primeiro Stage, eu me propus a ir em busca das subcategorias da área escolhida. Por isso, optei por ir em busca de artigos que pudessem me auxiliar nesse processo Top Down. Encontrei alguns recursos, os quais abordo no [documento de estudo](#), e realizei a leitura do artigo “[Summary of over Fifty Years with Brain-Computer Interfaces—A Review](#)”, que me permitiu compreender a história e o desenvolvimento da área.

Planejamento: [descrever o que pretende fazer para realizar a próxima ENTREGA]

Para a próxima semana, meu foco estará em aprofundar a compreensão do relacionamento entre interfaces cérebro-máquina (BCI) e Inteligência Artificial (IA). Enquanto as últimas semanas foram dedicadas aos fundamentos da Neurociência Computacional e BCIs, o próximo passo é explorar de forma mais profunda como a IA pode aprimorar a interpretação de sinais cerebrais, possibilitando a tradução de padrões complexos de atividade neural em comandos precisos.

Observação: [caso precise fazer alguma observação, de qualquer “natureza”]

ACEITE DA ENTREGA:

CEDRIC LUIZ DE CARVALHO: Go! ▾

RELATÓRIO REFERENTE A ENTREGA DO DIA 19 DE SETEMBRO DE 2024

Ao optar pela área de conhecimento *Neurociência Computacional*, pude observar que a minha decisão quanto à especialidade a ser trabalhada no processo da Residência em Inteligência Artificial, cursada no segundo semestre de 2024, está partindo de uma visão Top Down. Nesse sentido, o meu primeiro gate está concentrado em buscar o tema final, dentro dessa grande área, através de uma decomposição/categorização. Esse interesse surgiu por eu possuir desde a infância a curiosidade pela área de biológicas e o seu funcionamento. Ao longo da minha graduação, comecei a acompanhar superficialmente o trabalho do pesquisador [Luiz F. S. Borges](#) através de mídias sociais, casos de aplicação, e decidi, agora, me aprofundar no assunto.

Objetivos:

- Compreensão da história, fundamentos, métodos e técnicas da Neurociência Computacional.

Passos adotados:

1. **Pesquisa de artigos:** Apesar de não possuir um abrangente conhecimento a respeito da área, foi a curiosidade e alguns casos de aplicação que me inspiraram a ir atrás do conhecimento que a compõe. A fim de encontrar artigos de revisão para compreender melhor o campo de estudo, pontuando desafios, oportunidades e evoluções, consultei o Google, o Scielo e o PubMed com termos de busca como “Neurociência Computacional”, “História Neurociência Computacional revisão”, “Computational Neuroscience review”. Como resultado, não tive muito sucesso, pois em sua maioria se tratavam de casos de aplicação ou de estudos muito antigos.
2. **Seleção de artigos:** Apesar de não ter atingido o objetivo do primeiro passo adotado, escolhi alguns artigos recentes para ir em busca de suas referências e encontrar informações que fundamentam a área. Um dos artigos mais citados dentro da minha seleção foi [Computational Neuroscience \(Eliasmith, C. \(2007\)\)](#), o qual é bem visto por contribuir para o estudo das bases físicas e biológicas da cognição humana. Porém, antes de iniciar a leitura, busquei sobre o tema em outros espaços, como YouTube. Posteriormente,

brevemente li a introdução do artigo, percebi que ele não conseguiria fornecer de maneira ampla as informações que eu buscava.

3. **Seminário:** No YouTube, encontrei um seminário que tem como tema o questionamento “[O que é neurociência computacional?](#)”, ministrado pela professora no Instituto de Informática da Universidade Federal Fluminense [Taiane Coelho Ramos](#), que tem como principal área de pesquisa neurociência e investigação de transtornos mentais, bem como também envolve aplicação de técnicas de Inteligência Artificial e Aprendizado de Máquina para análise de dados biológicos. O conteúdo abordado trouxe um esclarecimento muito sucinto e direto sobre a área, mas também muito aproveitado e bem apresentado. Com base nesse conteúdo, anotei diversos tópicos que serviram como ponto de partida para continuar o meu processo.
4. **Compreensão de alguns exames/técnicas adotadas para coleta de dados:** Direcionada pelo passo 3, fui em busca de compreender um pouco melhor a respeito dos exames realizados e suas interpretações. Os mais famosos são:
 - a. Eletroencefalograma (EEG): é uma técnica não invasiva que que capta informações cerebrais. Cada eletrodo colocado no couro cabeludo é responsável pela aquisição de uma série temporal, as quais são criadas devido à atividade elétrica do cérebro. Essa atividade pode ser interpretada de muitas maneiras, e é muito sensível a contextos. Por exemplo, muitas vezes um eletrodo pode ter dificuldade de captar dados por estar mal encaixado (como é o caso da nuca, em que há maior dificuldade para fixação, o que corrompe o dado), a presença de cabelo também pode interferir na maneira que essas ondas são captadas (hoje há hardware, como Emotiv EPOC, que lidam bem com isso), uma série temporal pode ser comprometida pelo simples piscar de olhos, pois ele interrompe a transmissão de informações e pode impactar de forma significativa. Além disso, esse exame foi o responsável por validar a existências de ondas cerebrais Alfa e Beta em seres humanos, antes observadas apenas em animais.
 - b. Eletrocorticografia (ECoG): divergente da anterior, trata-se de uma técnica invasiva de monitoramento eletrofisiológico que registra potenciais elétricos associados à atividade cerebral diretamente na superfície do córtex cerebral. A aquisição desses dados é muito mais difícil que por meio do EEG, pois exige agilidade e que pessoas prestes a serem operadas com comorbidades, como epilepsia, concordem em realizar a coleta dessas informações. Também há a

aplicação desse método em macacos, como veremos melhor mais adiante. Em resumo, apesar de um técnica consideravelmente mais invasiva, apresenta dados com uma qualidade consideravelmente superior ao método anterior.

Há dois vídeos que podem contribuir consideravelmente com a compreensão do ECoG. O primeiro explica a respeito dessa coleta de dados de maneira clara ([Electrocorticography \(ECoG\) Explained! | Neuroscience Methods 101](#)), enquanto o segundo vídeo exhibe uma aplicação de Machine Learning funcionando em tempo real enquanto a coleta está ocorrendo([Real-time face decoder with ECoG](#)).

- c. Ressonância Magnética Estrutural (sMRI): como o próprio nome indica, trata-se de uma ressonância, o que contribui para o diagnóstico de doenças degenerativas e/ou estudo de alterações estruturais. Porém, além de caro, esse método não realiza o registro de dados do funcionamento do cérebro. Ou seja, as atividades elétricas não podem ser registradas por esse método. Isso não o torna menos relevante, apenas exige um contexto de uso distinto.
 - d. Ressonância Magnética Funcional (fMRI): divergente da sMRI, essa abordagem capta o fluxo sanguíneo cerebral durante uma atividade, o que permite estudar o funcionamento do cérebro. Porém, além de um custo alto, a resolução temporal é lenta, pois demora cerca de 2 segundos para que toda a informação seja captada, o que resulta na perda de alguns dados. Além disso, um simples movimento pode corromper os dados, pois o aparelho capta movimentos, e ao movimentar a cabeça, essa diferença é considerada. A compreensão dessas informações são de grandíssima importância, dada a dificuldade no tratamento e na compreensão dos dados.
5. **Fontes de dados:** Curiosa a respeito sobre a “cara” dos dados, e com algumas sugestões da professora Taiane, explorei de forma visual e através de leitura de documentação, três bancos de dados.
- a. [Neurotycho](#): esse banco de dados possui informações de um macaco com respeito a dados obtidos através de sensores corporais e ECoG. Os autores deixam claro ser um projeto voltado não apenas para neurocientistas, mas para todos que possuem interesse em conhecer melhor a respeito da área.
 - b. [ABIDE](#): a iniciativa conta com dados de imagens cerebrais funcionais e estruturais, coletados de vários laboratórios ao redor do mundo. O

projeto foi criado para avançar nossa compreensão das bases neurais do autismo e não se limita a neurocientistas, sendo acessível a todos interessados na área. A ABIDE oferece duas grandes coleções, ABIDE I e ABIDE II, que agregam informações de mais de 24 laboratórios internacionais, promovendo a ciência aberta.

- c. [CONNECTOME](#): essa iniciativa entende que nos próximos anos, muitos projetos ao redor do mundo vão estudar como fatores como idade, crescimento e doenças afetam as conexões em constante mudança no cérebro humano. Para ajudar a coordenar essas pesquisas, o Connectome Coordination Facility (CCF) foi criado e tem como missão padronizar os dados e facilitar a troca de informações entre os pesquisadores.

O CCF foca em três coisas principais:

- i. Oferecer um tipo de "central de ajuda" para apoiar a coleta de dados de forma que eles sejam comparáveis entre diferentes estudos.
- ii. Manter e melhorar a infraestrutura tecnológica do HCP, possibilitando o armazenamento e distribuição dos dados do conectoma em plataformas como o ConnectomeDB e Amazon Web Services.
- iii. Agir como um "centro de harmonização" para garantir que os dados coletados por diferentes instituições sejam o mais comparáveis possível.

A ideia é criar uma base sólida para que toda essa pesquisa seja mais integrada e útil para entender as complexidades do cérebro humano.

6. **Grupos de Pesquisa:** ao longo de toda a trajetória até essa etapa, a Inteligência Artificial esteve presente em cada etapa do meu estudo. Mesmo em momentos que ela parecia um pouco distante, ideias de como os dados adquiridos poderiam ser aplicados surgiram. Porém, eu gostaria de compreender um pouco melhor a respeito de subáreas dentro da área que escolhi; como a área tem sido abordada. Encontrei alguns grupos como:

- a. [acesin](#): esse grupo foi formado na Universidade Federal do Rio de Janeiro, e está localizado principalmente na faculdade de Letras, devido a associação com a linguística. O objetivo deles é estudar a

Neurociência da Linguagem. Eu não me aprofundi em artigos publicados por eles, porém, de acordo com o portal que utilizam, fazem uso de modelos de linguagem para compreender os sinais adquiridos por meio de EEG ou ERPs e avaliar os impactos.

7. **Retorno a busca por artigos de revisão:** Após realizar uma pesquisa a respeito da área, e levando em consideração minha jornada até aqui, fui em busca de um artigo de revisão no Google Acadêmico, local em que eu não havia buscado. Inseri a busca “Computational Neuroscience review”, apliquei um filtro de data (inicie com o ano atual e reduzia um ano em cada busca quando não encontrava o que buscava). Dessa forma, consegui encontrar o artigo [“Summary of over Fifty Years with Brain-Computer Interfaces—A Review”](#). Ao ler a introdução, notei ser um artigo muito relevante e optei por estudá-lo.

8. **Início da Leitura:**

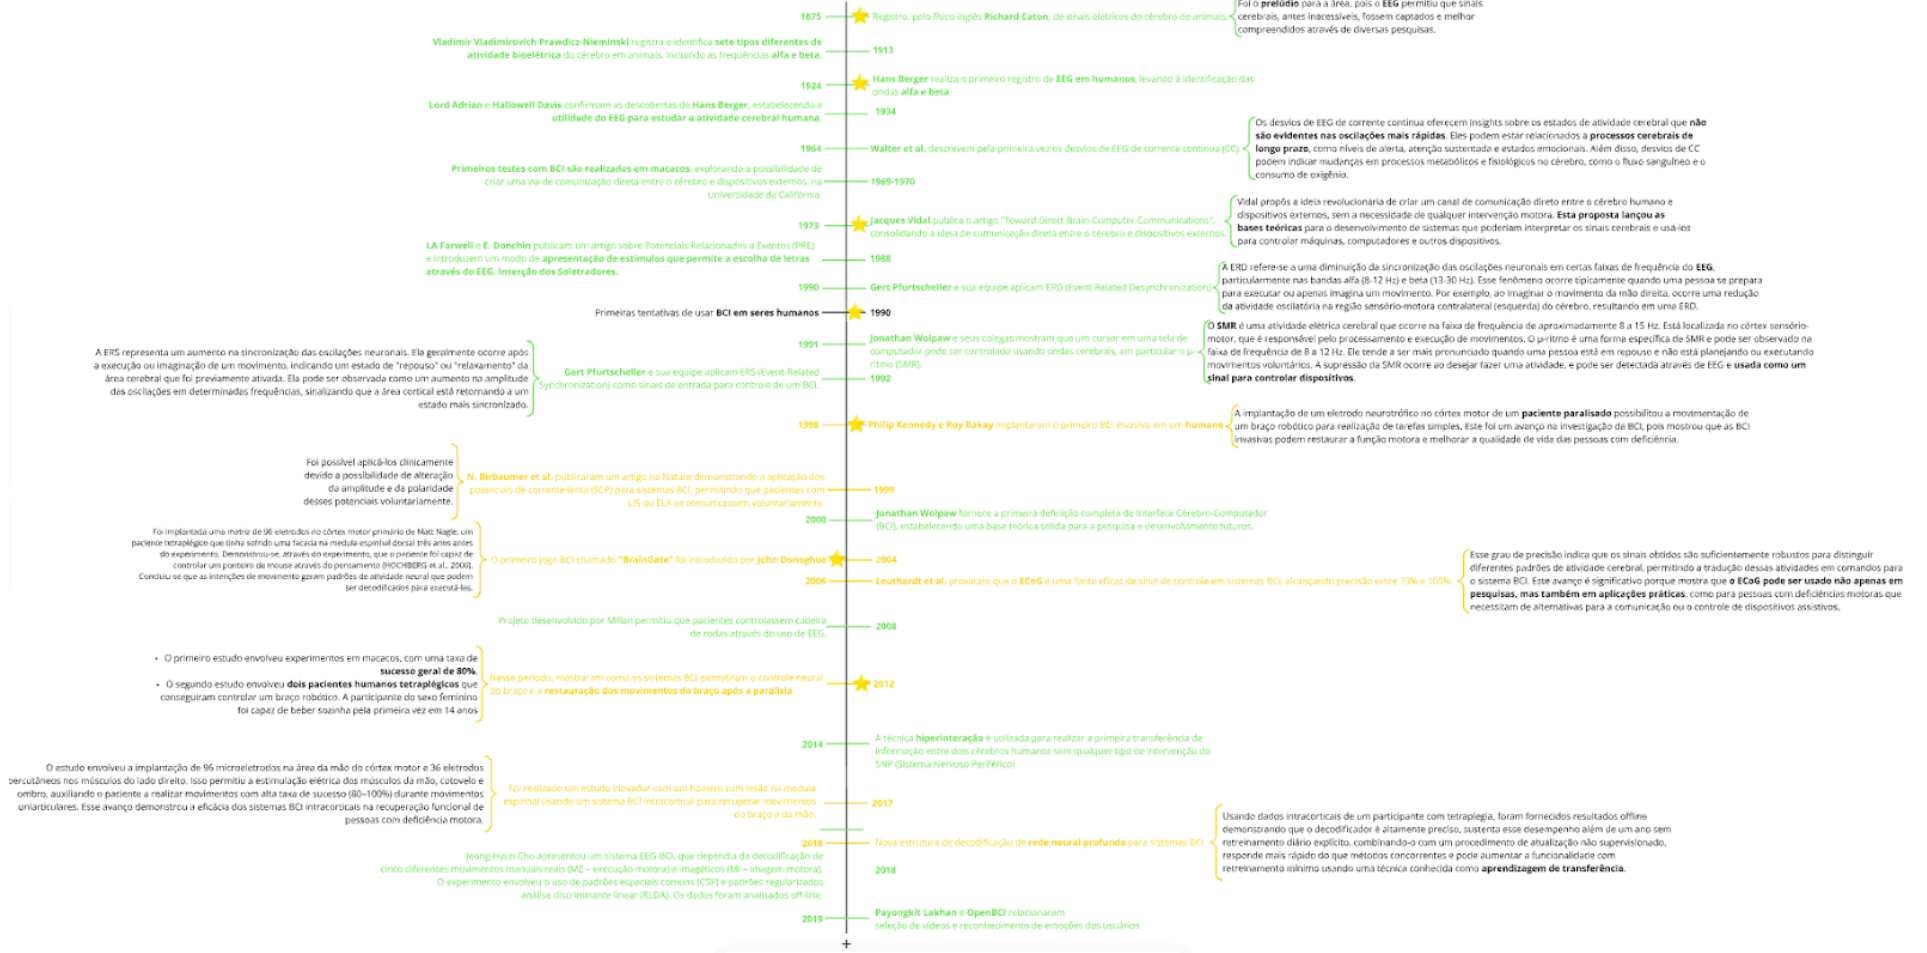
a. Estudo pela extensão *edit pdf*: [Artigo](#).

Legenda para as anotações do artigo:

- i. **Azul:** diz respeito às informações sobre os dados e técnicas utilizadas, bem como desafios associados a eles.
 - ii. **Vermelho:** consenso dos atuais autores/estudiosos, recursos mais valorizados e atualidade.
 - iii. **Laranja:** categorias, definições.
 - iv. **Verde:** história.
- b. [Linha Temporal](#) - Miro: para sintetizar as informações relacionadas a história que são oriundas do artigo, montei uma linha temporal no Miro. O artigo busca evidenciar os principais marcos, mas eu evidenciei com uma estrela principalmente dados relacionados à aplicação em humanos pela primeira vez, por exemplo. Além disso, é possível notar como alguns avanços ocorrem quando os métodos invasivos são adotados, embora nem sempre seja viável.

Dados Verdes: marcos associados a métodos não invasivos, em especial fazendo uso de dados adquiridos através de EEG.
Dados Amarelos: marcos associados a métodos invasivos, geralmente utilizando ECoG.

Esses dois exames contribuíram significativamente para o desenvolvimneto da área.



Termo de Aceite de Entrega

Objetivo deste documento

Este documento faz parte do Processo da disciplina Residência em IA e tem como objetivo formalizar o aceite da entrega considerando o planejado e o realizado para o período.

Data da Reunião (“gate”) de aprovação: 25 de set. de 2024

Participantes da Entrega [matriculados em Residência em IA]:

Isadora Stéfany Rezende Remigio Mesquita

Entrega: [descrever a ENTREGA: requisitos e produtos gerados: links para textos, códigos, vídeos etc.]

No **Stage 2**, concentrei meus estudos em aprofundar a compreensão do **relacionamento entre Interfaces Cérebro-Computador (BCI) e Inteligência Artificial (IA)**. Para isso, selecionei dois artigos atuais que me chamaram atenção, com o objetivo de visualizar melhor essa relação e enxergar os desafios, limitações e cenários em que alguns algoritmos foram aplicados:

- **Deep Learning for real-time neural decoding of grasp:** aborda o uso de técnicas de deep learning para decodificar sinais neurais em tempo real, com o objetivo de classificar diferentes tipos de "grasp" (pegadas) com base nos sinais neurais coletados do córtex motor de macacos. Ele utiliza redes LSTM (Long Short-Term Memory) para processar séries temporais de dados neurais (trens de spikes) e identificar padrões relacionados aos objetos sendo manipulados. O foco central do estudo é aprimorar a precisão da decodificação neural sem depender de conhecimento especializado em neurociência. Ao invés disso, a abordagem explora a capacidade dos modelos de deep learning de extrair correlações diretamente dos dados. Na abordagem, a LSTM apresentou uma melhora significativa. Link para leitura.
- **Neural Decoding for Intracortical Brain-Computer Interfaces:** aborda os desafios e avanços na decodificação neural de interfaces cérebro-computador intracorticais (iBCI), evidenciando como as iBCIs têm o potencial de restaurar a mobilidade e comunicação para pessoas com deficiências motoras severas. O foco do artigo está em técnicas de decodificação neural (como Filtro de Kalman, RNNs, Estimador Linear Ótimo e Treinamento Linear vs Retreinamento, as quais são altamente dependentes de algoritmos avançados de machine learning e redes neurais para interpretar sinais cerebrais complexos) que transformam os sinais do cérebro em comandos para dispositivos externos, como próteses. Link para leitura.

Além disso, acompanhei a **palestra do professor e pesquisador André Magno** a respeito de [Interface Cérebro-Computador e IA na educação](#), em que ele abordou aplicações, desafios e perspectivas futuras, bem como contribuiu para o conhecimento a respeito da relação de BCI e IA, e como essas áreas trabalham juntas.

Na semana passada, foi anunciada uma [graduação](#) na Tianjin University, na China, o que me chamou a atenção e fui compreender um pouco melhor a respeito do cenário da área no país. Por meio dessa investigação, encontrei a plataforma de código aberto [METABCI/TBC-TJU](#), que visa simplificar a condução

de experimentos BCI por meio da integração de conjuntos de dados variados e algoritmos modernos, dando suporte tanto a **pesquisadores novatos quanto a especialistas na área**.

Além disso, fui convidada pelo residente Marcelo a conhecer um pouco melhor a respeito do [Instituto Santos Dumont](#), que possui pesquisas e abordagens voltadas para a área de estudo.

Documento gerado: [Residência Stage 2](#)

Planejamento: [descrever o que pretende fazer para realizar a próxima ENTREGA]

Para a próxima semana, meu foco estará concentrado em entender outras abordagens associadas ao uso de IA, processamento dos dados adquiridos e explorar a METABCI (compreender melhor a respeito do que está sendo desenvolvido e agilidade de processamento discutida pelos fundadores).

Observação: [caso precise fazer alguma observação, de qualquer “natureza”]

ACEITE DA ENTREGA:

LEONARDO ALVES: Em análise! ▾

RELATÓRIO REFERENTE A ENTREGA DO DIA 25 DE SETEMBRO DE 2024

Objetivos:

- Aprofundar a minha compreensão em relação ao relacionamento entre Interfaces Cérebro-Computador (BCI) e Inteligência Artificial (IA).

Passos adotados:

1. **Palestra do professor e pesquisador André Magno sobre BCI na educação:** [palestra](#)
 - a. A apresentação aborda interfaces cérebro-computador (BCI) e inteligência artificial na educação, destacando suas aplicações e impactos. O palestrante explora como essas tecnologias podem personalizar o aprendizado, auxiliar alunos neurodivergentes e os desafios éticos envolvidos. A discussão enfatiza a importância de se adaptar às inovações tecnológicas no ensino, mostrando casos reais de uso principalmente na China.
2. Fundação de uma graduação em BCI na China: [curso](#)
3. [METABCI/TBC-TJU](#): MetaBCI é uma plataforma de código aberto desenvolvida sob a liderança do Prof. Minpeng Xu da Universidade de Tianjin, na China, voltada para interfaces cérebro-computador (BCI) não invasivas. A plataforma possui três componentes principais que facilitam a importação, pré-processamento de dados de EEG e a implementação de algoritmos de decodificação. Além de simplificar a condução de experimentos BCI, ela integra conjuntos de dados variados e algoritmos modernos, dando suporte tanto a **pesquisadores novatos quanto a especialistas na área**.
 - a. Pontos Chave
 - i. MetaBCI é a primeira plataforma de código aberto na China focada em interfaces cérebro-computador não invasivas.
 - ii. A plataforma é composta por três partes principais: **brainda**, **brainflow** e **brainstim**, que atendem diferentes fases do processamento de dados de EEG.

- iii. O MetaBCI visa simplificar a execução de experimentos BCI, reduzindo o tempo gasto no pré-processamento de dados.
 - iv. A documentação e as contribuições da comunidade são incentivadas para aprimorar continuamente a plataforma.
4. [Artigo Deep Learning for real-time neural decoding of grasp](#): discorre a respeito do uso de técnicas de **deep learning** para interpretar sinais neurais e decodificá-los em ações motoras, especificamente para controlar o movimento de preensão de uma mão. Ou seja, o foco está em como algoritmos avançados podem ser aplicados para entender, em tempo real, os comandos que o cérebro envia para a mão durante o ato de segurar objetos.

Os pesquisadores desenvolveram modelos que utilizam deep learning para decodificar sinais cerebrais complexos captados por eletrodos, com o objetivo de transformar esses sinais em comandos precisos para controlar próteses robóticas. A inovação nesse artigo é que o sistema consegue fazer isso de forma rápida e em tempo real, o que é crucial para aplicações práticas, como no controle de próteses para pessoas que perderam membros. As técnicas de deep learning mostraram-se promissoras, superando modelos mais antigos em precisão e velocidade. Isso traz perspectivas a respeito de um controle mais natural e eficiente de dispositivos por meio de BCIs, permitindo que pessoas com deficiências motoras tenham uma interação mais intuitiva com suas próteses.

5. [Artigo Neural Decoding for Intracortical Brain-Computer Interfaces](#): nesse artigo, que trabalha com métodos invasivos de aquisição de dados, é abordado como sinais neurais, captados diretamente do cérebro, podem ser decodificados para controlar dispositivos externos, como próteses robóticas. Ele foca em iBCIs que utilizam eletrodos implantados no cérebro para captar sinais neurais, com o objetivo de ajudar pessoas com deficiências motoras severas.

Diversas técnicas de decodificação neural são discutidas, como o uso de filtros de Kalman e RNNs. Essas abordagens processam os sinais neurais, que são sequenciais e complexos, para transformá-los em comandos motores em tempo real, assim como o artigo anterior. Um dos desafios abordados no artigo é a não estacionariedade dos sinais neurais, ou seja, como esses sinais variam com o tempo, dificultando o trabalho dos decodificadores. A conclusão do artigo sugere que avanços nas técnicas de decodificação neural, principalmente com o uso de IA e machine learning, são essenciais para melhorar a precisão e adaptabilidade das BCIs. Isso torna essas

tecnologias mais promissoras para aplicações práticas, como a reabilitação de pacientes e o controle de próteses.

6. [Instituto Santos Dumont](#): Organização Social vinculada ao Ministério da Educação (MEC), e que atua nas áreas de saúde materno-infantil, saúde da pessoa com deficiência, neurociências e neuroengenharia. Atualmente, estão trabalhando em BCIs e disponibilizaram, inclusive, um [desafio](#) na plataforma Kaggle a fim de estimular o conhecimento a respeito da área e avançar em soluções.

APÊNDICE 2

Termo de Aceite de Entrega

Objetivo deste documento

Este documento faz parte do Processo da disciplina Residência em IA e tem como objetivo formalizar o aceite da entrega considerando o planejado e o realizado para o período.

Data da Reunião (“gate”) de aprovação: 3 de out. de 2024

Participantes da Entrega [matriculados em Residência em IA]:

Isadora Stéfany Rezende Remigio Mesquita

Entrega: [descrever a ENTREGA: requisitos e produtos gerados: links para textos, códigos, vídeos etc.]

No **Stage 3**, busquei compreender outras abordagens **Interfaces Cérebro-Computador (BCIs)** associadas ao uso de **Inteligência Artificial (IA)**. Com base nos dados adquiridos por meio de EEG, fui em busca de técnicas abordadas atualmente:

- **[Deep feature extraction from EEG signals using xception model for emotion classification](#)**: O artigo propõe realizar a classificação de emoções através da extração de características de sinais de EEG. Para isso, ele defende a utilização de arquiteturas DCNN e a Transformada de Wavelet para extração de características. Em resumo, atingindo resultados consideravelmente melhores que outros artigos abordados pelos autores, eles acreditam que arquiteturas como Xception são o "futuro" dessa aplicação, mas conscientes que os sinais de EEG são sensíveis e que tanto a sua classificação quanto generalização podem ser comprometidas a depender do pré-processamento e modelos de classificação utilizados.
- **[Emerging Trends in EEG Signal Processing: A Systematic Review](#)**: O objetivo principal deste estudo de pesquisa é explorar completamente a infinidade de aplicações de pesquisa baseadas em EEG presentes na literatura existente. Dessa forma, publicado em 2024, ele busca abordar métodos tradicionais e inovadores e quais pontos fortes e limitantes essas abordagens possuem. Além disso, assim como o primeiro artigo, ele ressalta que estudos com métodos tradicionais mesclados com métodos inovadores estão apresentando excelentes resultados em comparação a abordagens isoladas.

Como proposto na semana passada, comecei a explorar a plataforma [METABCI/TBC-TJU](#), que visa tanto facilitar o estudo da área para novatos quanto facilitar a implementação de soluções para pesquisadores experientes. Nela, há alguns algoritmos BCIs implementados. Com base no foco dessa Stage em dados EEG, optei por iniciar os meus estudos na EEGNet por meio do artigo [A robust multi-branch multi-attention-mechanism EEGNet for motor imagery BCI decoding](#).

Iniciei a criação da minha [tabela](#) de artigos para orientações futuras.

Planejamento: [descrever o que pretende fazer para realizar a próxima ENTREGA]

Para a próxima Semana, meu foco estará concentrado em finalizar os meus estudos do artigo da EEGNet e continuar explorando a plataforma METABCI.

Observação: [caso precise fazer alguma observação, de qualquer “natureza”]

ACEITE DA ENTREGA:

CEDRIC LUIZ DE CARVALHO: [Go! ▾](#)

APÊNDICE 3

Termo de Aceite de Entrega

Objetivo deste documento

Este documento faz parte do Processo da disciplina Residência em IA e tem como objetivo formalizar o aceite da entrega considerando o planejado e o realizado para o período.

Data da Reunião (“gate”) de aprovação: 10 de out. de 2024

Participantes da Entrega [matriculados em Residência em IA]:

Isadora Stéfany Rezende Remigio Mesquita

Entrega: [descrever a ENTREGA: requisitos e produtos gerados: links para textos, códigos, vídeos etc.]

No **Stage 4**, após definir o meu estudo voltado para dados de EEG, consegui direcionar melhor o meu foco. Dessa forma, concentrei-me em entender os diversos tipos de EEG com maior profundidade e mapear algumas das principais técnicas de pré-processamento de dados EEG, como extração de características/redução de dimensionalidade utilizada em dados de EEG, como:

- Métodos de Regressão
- Blind Source Separation:
 - PCA
 - ICA
 - CCA

Ainda não finalizei essa etapa, mas meu estudo pode ser acompanhado [aqui](#).

Além disso, realizei o estudo da arquitetura [EEGNet](#), como me propus a realizar no último gate. Por meio desse estudo, pude observar as diferenças estruturais que a tornam tão interessante para o processamento de sinais de EEG e a sua diferença em relação a outras arquiteturas convolucionais, como as que são abordadas em imagens e processamento de voz.

Planejamento: [descrever o que pretende fazer para realizar a próxima ENTREGA]

Para o próximo Stage, pretende reler o artigo da arquitetura EEGNet, pois compreendo que ele tem um nível de complexidade e quero ter esse conhecimento mais concreto. Além disso, irei retomar o artigo abordado no último Gate, o qual propõe mecanismos de atenção para a EEGNet bem como continuar o mapeamento de técnicas utilizadas no pré-processamento desses dados, focados em cada tipo de EEG.

Observação: [caso precise fazer alguma observação, de qualquer “natureza”]

ACEITE DA ENTREGA:

CEDRIC LUIZ DE CARVALHO: [Go!](#)

RELATÓRIO REFERENTE A ENTREGA DO DIA 10 DE OUTUBRO DE 2024


Objetivos: Finalizar os meus estudos do artigo da EEGNet e continuar explorando a plataforma METABCI.

1. Eletroencefalograma (EEG):

É um método de aquisição de dados cerebrais **não invasivo**, o qual capta a atividade elétrica do cérebro através de sensores, gerando ondas cerebrais que exibem o padrão de funcionamento do órgão. A quantidade de eletrodos utilizada é variável, mas a recomendação é que cubra toda a superfície do crânio. De acordo com a Sociedade Brasileira de Neurofisiologia Clínica (SBNC), recomenda a utilização do [Sistema Internacional 10-20](#), que é composto por 21 eletrodos.

Há cerca de 100 anos, Hans Berger identificou as primeiras ondas alfa e beta em humanos através do EEG. Contemporaneamente, ele é utilizado de forma complementar para diagnóstico de doenças neurológicas. No entanto, servindo como ferramenta de inovação e contribuindo com a evolução da ciência, ele também tem sido usado como um verdadeiro método de neuroimagem com extensões mais recentes em neurociência translacional e computacional. Dentre os principais contextos aplicados para captação de atividade cerebral, podemos pontuar os seguintes:

- 1.1. **EEG Clássico - Ondas Cerebrais:** nessa abordagem, o indivíduo está em repouso, realizando uma atividade ou em outro estado mental. Não há necessidade de estímulos externos específicos. As diferentes bandas de frequência das ondas cerebrais (alfa, beta, gama, etc.) são usadas para inferir o estado mental, como sono, relaxamento ou concentração. Dessa forma, é possível realizar o estudo da atividade cerebral em condições diversas.



Fonte: In vitro cell models merging circadian rhythms and brain waves for personalized neuromedicine.

- 1.2. **Potenciais Relacionados a Eventos (ERP):** nesse contexto, o sinal é registrado enquanto a pessoa está realizando uma atividade ou uma sequência de atividades, submetida a estímulos específicos (sensorial, cognitivo ou motor). O objetivo é observar a resposta cerebral **ligada ao evento**, como a percepção de um som ou imagem.

A média de múltiplas ocorrências do estímulo é feita para isolar o sinal, visto que o sinal de ERP é mais fraco e pode ser ofuscado pelo ruído do EEG. Esse ruído pode ser causado tanto por ruído fisiológico, que são atividades cerebrais não associadas ao estímulo (o cérebro está sempre ativo) quanto por ruído ambiental e/ou técnico, causados por equipamentos eletrônicos próximos, como monitores, luzes ou dispositivos de comunicação, que podem gerar interferências eletromagnéticas captadas pelos eletrodos, aparecendo no sinal como ruído ou movimento de elétrons em componentes eletrônicos, como amplificadores. Assim, é possível realizar o estudo do processamento cognitivo relacionado a estímulos específicos, como atenção, percepção ou memória.

- 1.3. **Potenciais Visuais Evocados em Estado Estacionário (SSVEPs):** nessa abordagem, o contexto de captação dos dados trata-se do registro de ondas cerebrais enquanto o sujeito é exposto a **estímulos visuais contínuos** que piscam a uma frequência constante. Para compreender os dados adquiridos, a resposta cerebral é sincronizada com a frequência do estímulo visual (flicker). Essa técnica depende de uma estimulação visual constante e repetida, o que pode não ser necessário em outros tipos de análises de EEG. Assim, é geralmente usado em interfaces cérebro-computador (BCI), onde a frequência do estímulo visual pode ser usada para controlar dispositivos.

2. Fluxograma de Processamento de sinais de EEG para Classificação:

2.1. **Pré-processamento de Dados:** essa etapa é responsável, principalmente, pela remoção de ruídos. Como comentado anteriormente, dados biológicos e/ou externos podem influenciar nos sinais cerebrais, dificultando a sua utilização. Com base nisso, é possível elencar alguns métodos utilizados nessa etapa do fluxo:

2.1.1. **Métodos de Regressão:** essa técnica se mostrou eficaz e bastante utilizada para a remoção de artefatos/ruídos em sinais de EEG, como os causados por movimentos oculares (EOG - eletrooculograma) ou pela atividade cardíaca (ECG - eletrocardiograma). Esses artefatos interferem na análise dos dados, uma vez que sinais externos, como piscadas de olho (afetam sinais adquiridos pelos eletrodos frontais) ou batimentos cardíacos, podem mascarar os sinais cerebrais que se deseja estudar. O método de regressão oferece uma solução simples e eficiente para mitigar essa interferência. Com base na relação estimada, o ruído é subtraído do sinal EEG. Ou seja, o método "corrige" o sinal removendo a contribuição do EOG ou ECG no EEG. Isso resulta em um sinal EEG "limpo", com menos interferências de ruídos fisiológicos

O primeiro passo em sua aplicação é identificar a relação entre os ruídos e o sinal de EEG. Para realizar essa atividade, o método usa canais de referência, que são gravações simultâneas de sinais como o EOG ou ECG. Eles são usados para identificar as porções dos dados de EEG que contêm ruídos. O ponto negativo dessa abordagem é justamente a dependência desses sinais de referência para sua aplicação.

2.1.2. **Blind Source Separation (BSS):** Os métodos contidos em BSS são baseados na hipótese de que uma combinação de vários sinais originais distintos resulta nos sinais observados em uma gravação **multicanal**. Dessa forma, não são necessários mais canais de referência nem informações anteriores. Algumas técnicas contidas dentro desse método:

2.1.2.1. **Análise de Componentes Principais (PCA):** é uma técnica estatística utilizada para redução de dimensionalidade, focando em reter a maior quantidade de variância dos dados em menos dimensões, ou seja, simplificar os dados enquanto preserva a maior parte da informação relevante. Quando aplicada a sinais de EEG, como no caso de remoção de ruídos, a PCA pode ser uma ferramenta útil, mas tem limitações importantes em comparação com outras técnicas como o ICA. Enquanto o PCA é bom para capturar padrões de variância, ele não considera a independência estatística das fontes, o que é crítico para remover artefatos que

são **independentes** dos sinais cerebrais (como no caso de piscar de olhos ou batimentos cardíacos).

- 2.1.2.2. **Análise de Componentes Independentes (ICA)**: o ICA procura identificar componentes que não compartilham informações estatísticas entre si, ou seja, que são originados de fontes **independentes**. Para que seja possível utilizá-lo, é necessário que o número de canais (ou sinais misturados) seja maior que o número de fontes de sinal. Por exemplo, se há 16 eletrodos envolvidos na captação dos sinais por meio do EEG, é necessário que o número de fontes principais seja inferior ou igual ao número de eletrodos.

Por isso, se tenho quatro fontes (atividade cerebral de uma região do cérebro, atividade cerebral de outra região do cérebro, ruído causado por piscadas e ruído causado pelos batimentos cardíacos) e 16 eletrodos, serei capaz de separar as fontes dos sinais envolvidos. Caso o número de eletrodos seja inferior a quatro, não, pois a técnica de ICA não será capaz de separar os sinais corretamente, visto que não há dados suficientes para "desfazer" a mistura.

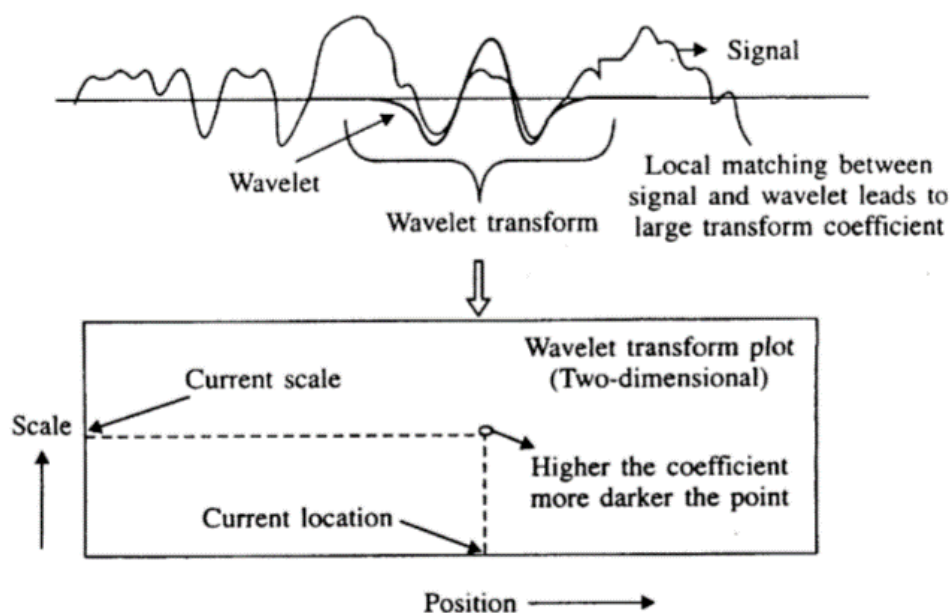
O algoritmo faz isso aplicando uma **transformação linear** nos sinais misturados (matriz de mistura), de modo a maximizar essa independência. Para separar os sinais, o ICA também pressupõe que os componentes originais tenham uma distribuição **não gaussiana**. Isso é útil, porque a mistura de vários sinais independentes geralmente segue uma distribuição mais gaussiana, então ao encontrar componentes com distribuições não gaussianas, o ICA pode identificar as fontes subjacentes.

- 2.1.2.3. **Análise de Componentes Canônicas (CCA)**: é amplamente usado em BCI cerebral baseado em SSVEP para identificar os componentes de frequência de EEG que caracterizam frequências de estímulo visual, identificando a frequência dominante que melhor corresponde à frequência do estímulo visual. É importante evidenciar que ao passar por estímulos visuais distintos, como por exemplo luzes piscando, o cérebro da pessoa responde diferente, gerando respostas neurais que contêm componentes nas mesmas frequências ou harmônicos.

Ela mede a **correlação entre o sinal de EEG e uma série de senóides** que correspondem às frequências esperadas dos estímulos visuais. A ideia é identificar qual frequência de estímulo visual gerou a maior resposta cerebral. Isso ocorre ao encontrar

uma combinação linear dos sinais de EEG e dos sinais de referência (seno e cosseno das frequências de estímulo) que maximiza a correlação entre eles.

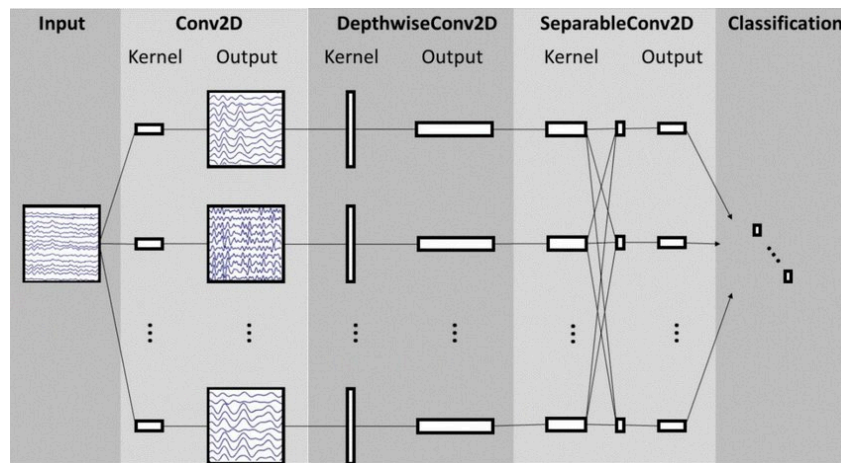
- 2.1.2.4. **Transformada de Wavelet:** é uma técnica de análise de sinais alternativa a Transformada de Fourier, a qual é bastante utilizada em processamento de áudio e voz. Nesse caso, ela converte um sinal do domínio do tempo para um domínio misto de tempo e frequência. Ela é muito útil para a análise de sinais não estacionários, como os sinais de EEG, que variam ao longo do tempo em termos de suas frequências. Por meio da decomposição do sinal em diferentes escalas e frequências, utilizando uma **função base chamada wavelet**, essa função base é ajustada e escalada ao longo do tempo para capturar tanto os componentes de alta frequência (detalhes finos) quanto os de baixa frequência (estruturas mais amplas) do sinal. O resultado é um mapa bidimensional (tempo e frequência) que permite uma análise detalhada da evolução temporal das frequências no sinal. A principal vantagem dela em relação a outras técnicas de decomposição de sinais, como a Transformada de Fourier, é justamente a capacidade de preservar a informação temporal, permitindo uma análise mais detalhada dos sinais dinâmicos.



Fonte: Aplicação De Wavelets Na Análise De Rádio Emissões Solares.

3.EEGNet:

A EEGNet é uma Rede Neural Convolutacional desenvolvida justamente para lidar com dados de EEG. Apesar da utilização de redes convolucionais oriundas tanto da Visão Computacional quanto do Processamento de Áudio e Voz, os desenvolvedores entenderam que elas foram aplicadas em paradigmas únicos, não sendo possível compreender como elas se generalizam. Por isso, a EEGNet é projetada para ser compacta e eficiente, possibilitando a classificação de diferentes paradigmas de BCI com um número significativamente menor de parâmetros em comparação a redes neurais convolucionais convencionais.



Fonte: EEGNet: a compact convolutional neural network for EEG-based brain-computer interfaces

Ela é uma rede compacta com capacidade de generalização, o que era bastante criticado pelos autores que a desenvolveram. Ela utiliza camadas convolucionais projetadas especificamente para capturar tanto as informações temporais quanto as espaciais presentes nos sinais de EEG. Inicialmente, filtros temporais são aplicados para aprender características que estão associadas a padrões oscilatórios ao longo do tempo, um aspecto crucial dos sinais de EEG. Em seguida, filtros espaciais entram em ação para extrair as relações entre os diferentes eletrodos ou canais de EEG, o que permite capturar a distribuição espacial da atividade cerebral. Essa combinação de informações temporais e espaciais é fundamental para representar a natureza complexa e multivariada dos sinais de EEG, oferecendo uma visão detalhada das variações dinâmicas e regionais da atividade cerebral.

A Camada Depthwise Separable Convolution é utilizada para melhorar a eficiência computacional. Essa técnica separa a convolução espacial da convolução temporal, o que reduz significativamente o número de parâmetros da rede. Esse tipo de convolução também

umenta a capacidade da rede de aprender padrões complexos sem aumentar a complexidade do modelo.

A EEGNet utiliza uma convolução separável 2D (Separable Conv 2D), que aprimora a eficiência ao combinar as informações temporais e espaciais de maneira mais eficaz. Esse processo envolve duas etapas: primeiro, realiza-se a convolução depthwise, seguida pela convolução pointwise. Essa decomposição do aprendizado espacial e temporal em etapas separadas não apenas melhora a eficiência do modelo, como também reduz o número de parâmetros, tornando-o mais leve e ágil.

Após a extração das características por meio dessas diversas convoluções (Conv2D, DepthwiseConv2D e SeparableConv2D), os dados são então passados para a camada final de classificação. Nessa fase, os vetores de características extraídos servem para prever a classe de interesse, que, no contexto dos sinais de EEG, pode estar relacionada a estados cognitivos, imaginação de movimentos (como em BCI de Imaginação Motora, como abordada no desafio do Kaggle do Instituto Santos Dumont) ou respostas a estímulos (como em paradigmas de SSVEP ou ERP).

A separação clara entre as convoluções temporais (Conv2D), espaciais (DepthwiseConv2D) e a combinação dessas características (SeparableConv2D) permite a rede capturar padrões complexos nos sinais de EEG com baixa sobrecarga computacional.

Em contraste com as CNNs tradicionais, que são projetadas principalmente para processar dados de imagens, essa rede se destaca por sua capacidade de lidar eficientemente com sinais biológicos não estacionários, extraíndo características temporais e espaciais de forma otimizada. Isso a torna mais adequada para tarefas envolvendo EEG, onde há uma necessidade de capturar informações dinâmicas e multivariadas de maneira eficiente.

Fonte: EEGNet: a compact convolutional neural network for EEG-based brain-computer interfaces

Layer	Input ($C \times T$)	Operation	Output	Number of Parameters
1	$C \times T$	$16 \times \text{Conv1D} (C \times 1)$	$16 \times 1 \times T$	$16C + 16$
	$16 \times 1 \times T$	BatchNorm	$16 \times 1 \times T$	32
	$16 \times 1 \times T$	Transpose	$1 \times 16 \times T$	
	$1 \times 16 \times T$	Dropout (.25)	$1 \times 16 \times T$	
2	$1 \times 16 \times T$	$4 \times \text{Conv2D} (2 \times 32)$	$4 \times 16 \times T$	$4 \times 2 \times 32 + 4 = 260$
	$4 \times 16 \times T$	BatchNorm	$4 \times 16 \times T$	8
	$4 \times 16 \times T$	Maxpool2D (2,4)	$4 \times 8 \times T/4$	
	$4 \times 8 \times T/4$	Dropout (.25)	$4 \times 8 \times T/4$	
3	$4 \times 8 \times T/4$	$4 \times \text{Conv2D} (8 \times 4)$	$4 \times 8 \times T/4$	$4 \times 4 \times 8 \times 4 + 4 = 516$
	$4 \times 8 \times T/4$	BatchNorm	$4 \times 8 \times T/4$	8
	$4 \times 8 \times T/4$	Maxpool2D (2,4)	$4 \times 4 \times T/16$	
	$4 \times 4 \times T/16$	Dropout (.25)	$4 \times 4 \times T/16$	
4	$4 \times 4 \times T/16$	Softmax Regression	N	$TN + N$
Total				$16C + N(T + 1) + 840$

REFERÊNCIAS:

Pavan, Barbara & Bianchi, Anna & Botti, Giada. (2022). In vitro cell models merging circadian rhythms and brain waves for personalized neuromedicine. *iScience*. 25. 105477. 10.1016/j.isci.2022.105477.

Gimenes Macedo, Humberto & Sodr , Zuleika & Fernandes, Francisco. (2016). APLICAÇÃO DE WAVELETS NA ANÁLISE DE RÁDIO EMISSÕES SOLARES. *Revista Univap*. 22. 96. 10.18066/revistaunivap.v22i39.420.

J. Von Zuben, Fernando & R. F. Attux, Romis. Análise de Componentes Independentes. Acessado em: https://www.dca.fee.unicamp.br/~attux/topico_10_2016.pdf

EEGLab Wiki, acessado em: https://eeglab.org/tutorials/06_RejectArtifacts/RunICA.html

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*, 15(5), 056013. doi:10.1088/1741-2552/aace8c

Termo de Aceite de Entrega

Objetivo deste documento

Este documento faz parte do Processo da disciplina Residência em IA e tem como objetivo formalizar o aceite da entrega considerando o planejado e o realizado para o período.

Data da Reunião (“gate”) de aprovação: 16 de out. de 2024

Participantes da Entrega [matriculados em Residência em IA]:

Isadora Stéfany Rezende Remigio Mesquita

Entrega: [descrever a ENTREGA: requisitos e produtos gerados: links para textos, códigos, vídeos etc.]

No **Stage 5**, como proposto como objetivo no Gate 4, continue o estudo de fluxograma de processamento de sinais EEG para Classificação. Nessa Semana, pode acrescentar ao meu conhecimento as técnicas a seguir:

- Filtering Methods:
 - **Filtragem de Frequência:** Técnica que separa componentes de um sinal com base em suas frequências, usando filtros passa-baixa e passa-alta para remover ruídos indesejados
 - **Filtragem Adaptativa:** Ajusta automaticamente os parâmetros do filtro em resposta às variações do sinal e do ambiente, sendo útil na remoção de ruídos.
 - **Filtragem de Wiener:** Método estatístico que minimiza o erro quadrático entre um sinal estimado e o real, ideal para sinais com ruídos gaussianos.
 - **Modelagem Auto-Regressiva:** Utiliza valores passados de um sinal para prever seus valores futuros, comum na análise de séries temporais.
 - **Transformada Rápida de Fourier:** Algoritmo eficiente para calcular a transformada de Fourier, permitindo a análise de frequências de um sinal e sua conversão para o domínio da frequência.
 - **Padrão Espacial Comum:** Técnica de extração de características que maximiza a discriminação entre duas classes de sinais, utilizada em aplicações de interface cérebro-computador (BCI) para classificar sinais de EEG.

Ainda não finalizei essa etapa, mas meu estudo pode ser acompanhado [aqui](#).

Além disso, realizei o estudo do artigo [EEG motor imagery decoding: A framework for comparative analysis with channel attention mechanisms](#), como proposto. Por meio desse estudo, pude evidenciar como mecanismos de atenção por canais ajudam a identificar quais regiões do cérebro estão mais ativas durante a simulação de movimentos. Isso é possível porque é calculado um score de atenção para cada um desses canais (eletrodos), refletindo sua relevância para a tarefa. Esses scores são então normalizados, geralmente utilizando a função softmax, que possibilita selecionar as informações mais relevantes.

Planejamento: [descrever o que pretende fazer para realizar a próxima ENTREGA]

Para a próxima Semana, quero colocar em prática a rede estudada e me aprofundar em outro algoritmo da área, como o ShallowConvNet.

Observação: [caso precise fazer alguma observação, de qualquer “natureza”]

ACEITE DA ENTREGA:

CEDRIC LUIZ DE CARVALHO: Go! ▾

RELATÓRIO REFERENTE A ENTREGA DO DIA 16 DE OUTUBRO DE 2024

Objetivos: Rer o artigo da arquitetura EEGNet, pois compreendo que ele tem um nível de complexidade e quero ter esse conhecimento mais concreto. Além disso, irei retomar o artigo abordado no último Gate, o qual propõe mecanismos de atenção para a EEGNet bem como continuar o mapeamento de técnicas utilizadas no pré-processamento desses dados, focados em cada tipo de EEG.

1. Fluxograma de Processamento de sinais de EEG para Classificação:

1.1. Filtering Methods:

1.1.1. **Filtragem de frequência:** A filtragem de frequência é uma técnica de separação clássica simples para eliminar artefatos dos sinais de EEG desejados. Há quatro tipos de filtros de frequência que podem ser considerados: **filtros passa-baixa, passa-alta, passa-banda e corta-banda**. No entanto, esse método não é eficiente se as distribuições espectrais de artefatos e os componentes de EEG se sobrepõem. No caso de sobreposição, técnicas alternativas de remoção de artefatos são necessárias

1.1.2. **Filtragem Adaptativa:** A filtragem adaptativa é baseada na suposição de que o sinal de EEG de interesse e o artefato **não são correlacionados**. Este filtro usa um sinal de referência e produz um sinal estimado que é correlacionado com o artefato; a estimativa é então subtraída dos sinais primários para produzir um sinal de EEG sem ruído. A filtragem adaptativa usa o algoritmo dos mínimos quadrados médios (**LMS**), que é linear em convergência, para avaliar os sinais limpos atualizando o parâmetro de peso. Outro algoritmo de otimização, o algoritmo dos mínimos quadrados recursivos, é quadrático em convergência e é uma **extensão do LMS**. Dependendo do tipo de algoritmo dos mínimos quadrados recursivos, sua convergência pode ser mais rápida do que a do algoritmo LMS, mas seu custo computacional é maior. Uma desvantagem do uso da filtragem adaptativa é que fornecer entrada de referência requer mais sensores.

- 1.1.3. **Filtragem de Wiener:** trata-se de uma técnica estatística para minimizar o erro quadrático médio entre os sinais de interesse e os sinais estimados, gerando um filtro linear invariante no tempo. Embora a filtragem de Wiener não exija uma referência adicional, como o processo de minimização é aplicado para estimar as densidades espectrais de potência do sinal de EEG e do sinal de artefato, o processo computacional pode ser complicado.
- 1.2. **Métodos de Extração de Características:** Os sinais de EEG contêm muita informação, tornando crucial a extração adequada de características para algoritmos de ML e DL. Essa extração reduz a dimensionalidade dos dados, mantendo as informações essenciais. Métodos de extração variam conforme a tarefa, incluindo os domínios de tempo (como ICA, PCA e modelos AR), de frequência (como FFT e método de Welch) e de tempo-frequência (como WT e STFT). Além disso, medidas estatísticas como média e variância também são usadas.
- 1.2.1. **Modelagem Auto Regressiva:** O modelo autorregressivo (AR) é interessante devido aos sinais de EEG serem não estacionários, prevendo esses sinais com base em sua ordem e parâmetros. A ordem do modelo AR varia entre 1 e 12, e uma escolha inadequada pode prejudicar o desempenho e aumentar os custos computacionais. Métodos adaptativos de AR, como o **filtro de Kalman**, melhoram a precisão da estimativa e a classificação de sinais. Apesar de proporcionar boa resolução de frequência e estimar espectros de potência em dados de EEG curtos, o modelo AR é sensível à seleção incorreta de ordem e parâmetros.
- 1.2.2. **Transformada rápida de Fourier:** FFT é um método eficaz para sinais estacionários. Ele transforma sinais do domínio do tempo para o domínio da frequência e implementa análise espectral. Neste método, as características são extraídas usando ferramentas matemáticas para calcular o PSD. A estimativa do PSD para uma banda relacionada pode ser computada com FFT, que usa métodos não paramétricos, como o método de Welch. Embora o FFT seja comumente usado no processo de análise de dados e funcione efetivamente para sinais estacionários, ele não é eficiente para dados não lineares e não estacionários, como sinais de EEG; além disso, os resultados obtidos por meio deste método não são confiáveis. Esta deficiência motivou os pesquisadores a desenvolver novos procedimentos e métodos para a análise de sinais não estacionários, como o método de decomposição

de Fourier, o método de decomposição de modo variacional (VMD) e o método de transformação de Hilbert-Huang (HHT).

- 1.2.3. **Padrão Espacial Comum (CSP)**: um método eficaz para a extração de características em aplicações de interface cérebro-computador (BCI), especialmente em tarefas de **imaginação motora**. Ele é utilizado para filtragem espacial, podendo operar em toda a trilha de dados ou em segmentos de tempo, sendo amplamente aplicado em tarefas de classificação binária. O objetivo do CSP é distinguir entre duas classes, minimizando a variância de uma delas e maximizando a da outra, o que é alcançado por meio da aplicação de filtros espaciais.

As principais vantagens do CSP incluem sua simplicidade e rapidez de execução. Porém, o método apresenta limitações na extração de características ótimas a partir de dados brutos de EEG, e sua eficácia pode ser comprometida por artefatos e pela posição dos eletrodos. Para mitigar essas limitações, alguns métodos de seleção de características espaciais podem ser mais eficientes.

Abordagens foram propostas para melhorar o CSP, incluindo:

- **Padrão Espaço-Espectral Comum (CSSP)**: otimiza a banda de frequência em cada posição do eletrodo, mas enfrenta desafios devido à não estacionariedade dos dados de EEG. Uma versão invariante do CSSP foi desenvolvida para lidar com ruídos, embora exija a definição de um parâmetro de remoção de ruído.
- **Padrão Espectral-Espacial Esperso Comum (CSSSP)**: busca um padrão espectral comum para todos os canais, melhorando o desempenho do CSP.
- **Padrão Espacial Comum de Sub-banda**: filtra sinais de EEG em múltiplas sub-bandas, extraindo características de cada uma de forma independente.
- **Padrão Espacial Comum de Banco de Filtros Discriminantes**: utiliza a razão de Fisher para melhorar a discriminação entre bandas de frequência.

- 1.3. **Algoritmos de Classificação**: A inteligência artificial abrange o aprendizado de máquina (ML), com o aprendizado profundo (DL) se destacando como uma área em rápido crescimento, especialmente em aplicações de classificação. O objetivo da classificação é prever os rótulos de classe de novos dados, sendo os algoritmos divididos em duas categorias:

convencionais e baseados em DL. Os métodos convencionais dependem de recursos artesanais e análises estatísticas, mas enfrentam dificuldades ao lidar com conjuntos de dados de alta dimensão. Em contrapartida, os algoritmos DL utilizam o aprendizado de representação, permitindo a extração automática de recursos em diferentes níveis de abstração, superando as limitações dos métodos tradicionais e oferecendo maior eficiência em tarefas complexas.

1.3.1. Algoritmos Convencionais de Classificação:

1.3.1.1. **Redes Neurais Convolucionais:** são modelos computacionais compostos por redes multicamadas de neurônios interligados por pesos ajustáveis, geralmente seguidos por funções de ativação não lineares, como a ReLU. Durante o aprendizado, as RNAs ajustam esses pesos para melhorar a precisão na classificação de dados. Métodos supervisionados complementares, como Bayes Ingênuo (NB), Máquina de Vetores de Suporte (SVM), K-Vizinhos Mais Próximos (KNN), Regressão Logística (LR), Floresta Aleatória (RF) e Análise Discriminante Linear (LDA), também são amplamente utilizados, cada um com características e vantagens específicas.

1.3.1.2. **Bayes Ingênuo:** O NB é um classificador probabilístico baseado no Teorema de Bayes que, por sua simplicidade e eficiência, requer pequenos conjuntos de treinamento. Simples, eficiente e requer pequenos conjuntos de treinamento. Ele tem se mostrado eficaz em tarefas de análise de sinais EEG, como detecção de eventos relacionados (ER), convulsões (SD) e imagética motora (MI). Contudo, sua principal limitação está na suposição de independência entre os atributos, o que pode impactar a precisão em cenários mais complexos.

1.3.1.3. **Máquina de Vetores de Suporte:** utiliza hiperplanos discriminantes para separar dados linear ou não linearmente, empregando funções kernel em casos mais complexos. Apesar de ser matematicamente sólido e eficiente para sinais EEG, seu desempenho depende da otimização de parâmetros, como a função kernel e o coeficiente de penalidade, que podem ser ajustados com algoritmos de otimização, como algoritmos genéticos e enxames de partículas. SVM tem sido amplamente aplicado em diagnósticos de distúrbios cerebrais, incluindo convulsões e Alzheimer.

1.3.1.4. **Floresta Aleatória (RF):** utiliza um conjunto de árvores de decisão, combinando suas previsões por votação ou média.

Este método aproveita classificadores fracos para criar modelos robustos, mas pode ser afetado pelo overfitting e pela instabilidade de árvores individuais. Ainda assim, a RF é altamente eficaz em grandes conjuntos de dados EEG, superando outros métodos supervisionados em desempenho.

- 1.3.1.5. **Análise Discriminante Linear (LDA):** técnica linear de redução de dimensionalidade e separação de classes que maximiza a separação entre classes ao minimizar a variabilidade dentro delas. Sua simplicidade e baixo custo computacional a tornam valiosa em sistemas BCI, como os baseados em MI e P300. Contudo, a abordagem linear limita seu desempenho em dados EEG não lineares.

1.4. EEG motor imagery decoding: A framework for comparative analysis with channel attention mechanisms:

O artigo propõe um framework para analisar e comparar diferentes abordagens de decodificação de imaginação motora (MI) em eletroencefalograma (EEG) utilizando mecanismos de atenção por canais. A imaginação motora envolve a simulação mental de movimentos, o que é amplamente utilizado em interfaces cérebro-computador (BCIs). O desafio é melhorar a precisão e robustez dessas decodificações, dada a natureza complexa e ruidosa dos sinais de EEG.

O framework apresentado permite comparar técnicas baseadas em deep learning com a introdução de mecanismos de atenção. Esses mecanismos ajudam a destacar os canais de EEG mais relevantes para a tarefa de classificação, aumentando a performance dos modelos ao priorizar as regiões cerebrais críticas para a imaginação motora. Os autores realizaram experimentos usando diferentes conjuntos de dados de MI, aplicando redes neurais convolucionais (CNNs) e outros métodos de deep learning aprimorados por atenção, e mostram que a inclusão desses mecanismos melhora significativamente a acurácia.

Mecanismos de Atenção por Canais:

Os mecanismos de atenção por canais são técnicas desenvolvidas para otimizar o desempenho de redes neurais, especialmente em tarefas que envolvem dados complexos, como sinais eletroencefalográficos (EEG). A ideia central desses mecanismos é **permitir que o modelo identifique quais partes da entrada são mais relevantes** para a tarefa que está sendo realizada, realçando a importância dos

canais mais informativos e reduzindo o peso daqueles que trazem informações menos úteis.

Quando um modelo processa dados, cada canal representa uma dimensão de informação. Por exemplo, em um sinal EEG, cada canal corresponde a um eletrodo que capta a atividade elétrica de uma região específica do cérebro. A atenção por canais funciona calculando um score de atenção para cada um desses canais, refletindo sua relevância para a tarefa proposta. Esses scores são então normalizados, geralmente utilizando a função softmax, que transforma os valores em uma escala que varia entre 0 e 1, garantindo que a soma total seja igual a 1. Com isso, os canais que são considerados mais importantes para a tarefa ganham um peso maior, enquanto aqueles que são menos relevantes são atenuados.

Existem diferentes tipos de mecanismos de atenção. A atenção global analisa todos os canais em conjunto, permitindo que a rede aprenda quais são mais informativos em um contexto amplo. Por outro lado, a atenção local pode focar em subconjuntos de canais ou em períodos temporais específicos, permitindo um enfoque mais detalhado em características ou momentos que são particularmente significativos.

Ao destacar as informações mais úteis, não apenas podemos melhorar a precisão do modelo, mas também oferecer uma forma de interpretação dos resultados. Isso significa que os pesquisadores e desenvolvedores podem entender melhor quais canais foram decisivos para as decisões do modelo, trazendo insights sobre o funcionamento do sistema e dos dados envolvidos.

No contexto do EEG e da decodificação de imaginação motora (MI), a atenção por canais ajuda a identificar quais regiões do cérebro estão mais ativas durante a simulação de movimentos, resultando em uma decodificação mais precisa dos sinais cerebrais. Isso é crucial para melhorar a eficiência das interfaces cérebro-computador (BCIs), que podem usar essas informações para interpretar as intenções do usuário e gerar respostas adequadas.

REFERÊNCIAS:

Dive into deep learning, acessado em:

https://pt.d2l.ai/chapter_attention-mechanisms/index.html

Jose Adenaldo S. Bittencourt Junior. AI Engineering at Deep Learning Brasil acessado em:

https://ww2.inf.ufg.br/~anderson/deeplearning/20181/mecanismos_de_atencao_redes_neurais_profundas_deep_learning.pdf

Gimenes Macedo, Humberto & Sodr , Zuleika & Fernandes, Francisco. (2016). APLICAÇÃO DE WAVELETS NA ANÁLISE DE RÁDIO EMISSÕES SOLARES. Revista Univap. 22. 96. 10.18066/revistaunivap.v22i39.420.

Pay Attention Explicando o Mecanismo de Atenção acessado em:

<https://lamfo-unb.github.io/2019/05/01/Pay-attention-Explicando-o-mecanismo-de-Atencao/>

APÊNDICE 4

Termo de Aceite de Entrega

Objetivo deste documento

Este documento faz parte do Processo da disciplina Residência em IA e tem como objetivo formalizar o aceite da entrega considerando o planejado e o realizado para o período.

Data da Reunião (“gate”) de aprovação: 30 de out. de 2024

Participantes da Entrega [matriculados em Residência em IA]:

Isadora Stéfany Rezende Remigio Mesquita

Entrega: [descrever a ENTREGA: requisitos e produtos gerados: links para textos, códigos, vídeos etc.]

No **Stage 6**, como proposto como objetivo no Gate 5, a implementação e estudo da Rede Neural Convolucional EEGNet que está sendo há um tempo estudada. Para isso, eu realizei o estudo de dois frameworks e implementações com ambos. No caso do primeiro, trabalhei com uma rede crua, ou seja, sem pré-treinamento, o que permite maior flexibilidade. No segundo, optei por explorar um modelo pré-treinado, mas que dentro do cenário estudado não mostrou grande diferença de desempenho, embora tenha exigido maior conhecimento de pré-processamento dessas informações.

- **METABCI:** [Estudo aqui](#).
- **MNE e Hugging Face:** [Estudo aqui](#).

Além disso, gerei um documento que explica o meu desenvolvimento e desafios encontrados durante esse processo, o qual pode ser consultado [aqui](#).

Além disso, realizei o estudo do [Sistema Internacional 10-20](#) para auxiliar no discernimento dessas informações.

Planejamento: [descrever o que pretende fazer para realizar a próxima ENTREGA]

Investigar outras arquiteturas e aprimorar a aplicação estudada.

Observação: [caso precise fazer alguma observação, de qualquer “natureza”]

ACEITE DA ENTREGA:

LEONARDO ALVES: **Em análise!** ▾

Objetivos: Para a próxima Semana, quero colocar em prática a rede estudada e me aprofundar em outro algoritmo da área, como o ShallowConvNet.

1. Colocando em prática o [METABCI](#):

No início da descoberta pelas ferramentas envolvidas na área de Interfaces Cérebro-Computador, eu pude iniciar uma compreensão a respeito das funcionalidades da ferramenta METABCI. Por meio dela, encontrei algoritmos próprios da área e direcionei os meus estudos para eles. Dessa forma, eu apliquei a rede EEGNet implementada por eles nos dados propostos no desafio [Motor Imagery Challenge](#), promovido pelo Instituto Santos Dumont.

Nesse processo, segui as orientações de uso propostos no repositório e utilizei o VSCode. Em seguida, transferi o desenvolvimento para o [Google Colab](#), a fim de facilitar o acesso.

As vantagens de utilizar essa ferramenta estão centradas em se tratar de uma comunidade ativa e engajada bem como permitir maior flexibilidade na personalização da arquitetura da rede, porém, não disponibilizaram modelos pré-treinados. Ou seja, as arquiteturas implementadas estão cruas, o que exige um grande volume de dados rotulados, o que pode ser desafiador na área, por isso a importância de outras abordagens. Quando um modelo é treinado do zero, ele precisa aprender padrões e estruturas diretamente a partir dos dados brutos, o que requer uma quantidade significativa de exemplos para desenvolver uma representação robusta. No entanto, dados de EEG possuem uma coleta cara e demorada, resultando em datasets menores e impactando a capacidade do modelo de generalizar.

Outro problema importante é o risco de overfitting. Como o modelo sem pré-treinamento começa com pesos aleatórios, ele tende a se adaptar excessivamente aos dados de treino, o que pode reduzir sua performance em novos dados. Esse efeito é mais comum em conjuntos de dados pequenos, onde o modelo tem poucas oportunidades de aprender a variedade necessária para generalizar bem. Apesar disso, o modelo não se adaptou bem ao cenário apresentado.

No caso de pré-treinamento, o modelo começa com pesos ajustados por meio de dados amplos e variados, o que facilita o ajuste fino posterior. Mas, sem esse ponto de partida, cada peso precisa ser ajustado do zero, exigindo mais tempo e processamento.

2. Colocando em prática o [MNE](#) e [Hugging Face](#):

Além da exploração anterior, também explorei outro framework, que é o [MNE](#). Trata-se de uma ferramenta python bem documentada e que possui modelos pré-treinados, o que

pareceu ser mais interessante, uma vez que poderemos conseguir driblar grande parte dos problemas abordados anteriormente.

Primeiro, a especialização do MNE para dados EEG é uma vantagem significativa. Ele oferece suporte direto para ler, processar e manipular os formatos comuns de arquivos de EEG, o que permite trabalhar diretamente com os dados brutos sem a necessidade de converter formatos ou escrever códigos complexos de entrada. Isso facilita a construção de fluxos de processamento de sinal que incluem desde o carregamento dos dados até a aplicação de filtros específicos, como o Notch de 60 Hz e o Butterworth na faixa de 0,5-250 Hz (já estavam aplicados nos dados que foram fornecidos no desafio). Além disso, o MNE traz recursos sofisticados para remoção de artefatos, incluindo o uso de ICA (Análise de Componentes Independentes), algo crucial para reduzir ruídos que podem interferir na detecção da intenção motora.

Outro ponto a ser considerado é a capacidade de visualização interativa dos dados. Ele oferece ferramentas para visualização em 3D, mapas de calor do scalp e visualizações de espectrogramas, o que permite uma análise exploratória dos dados. O que inclusive foi utilizado ao explorar essa ferramenta, auxiliando se a compreender se os sinais foram capturados e processados corretamente para identificar padrões de intenção motora, como levantar a mão direita ou esquerda.

Além disso, a compatibilidade do MNE com outras bibliotecas de machine learning, como scikit-learn e PyTorch, permite exportar os dados pré-processados para treinar modelos de aprendizado de máquina. Essa integração agiliza o processo.

Contudo, há também algumas limitações a considerar. O MNE, embora seja excelente para pré-processamento e visualização, não é focado em aprendizado profundo. Ele não possui recursos nativos para construir ou treinar redes neurais complexas, e por isso, o treinamento e a adaptação de redes como a EEGNet precisam ser feitos em outras bibliotecas, como o PyTorch. Esse uso fragmentado de ferramentas exige um cuidado maior para garantir que os dados estejam formatados corretamente entre as diferentes fases do pipeline.

O Hugging Face é um ambiente que permite acesso a diversos modelos pré-treinados, por isso foi a primeira alternativa. Lá eu pude encontrar um modelo bem documentado e decidi fazer uso dele. Porém, a principal limitação que encontrei ao realizar um fine tuning foi com relação ao número de canais. No modelo proposto, limitado a 3 canais. Por isso, precisei pré-processar os meus dados, e fiz isso com o MNE, utilizando ICA e Segmentação. Nesse caso, embora tenha iniciado também no VSCode, a maior parte da implementação foi realizada no Google Colab [aqui](#).

REFERÊNCIAS:

https://neurotechlab.socsci.ru.nl/resources/pretrained_imagery_models/

https://neurotechlab.socsci.ru.nl/resources/pretrained_imagery_models/#part-2---re-using-pre-trained-neural-networks

<https://huggingface.co/PierreGtch/EEGNetv4>

APÊNDICE 5

Termo de Aceite de Entrega

Objetivo deste documento

Este documento faz parte do Processo da disciplina Residência em IA e tem como objetivo formalizar o aceite da entrega considerando o planejado e o realizado para o período.

Data da Reunião (“gate”) de aprovação: 7 de nov. de 2024

Participantes da Entrega [matriculados em Residência em IA]:

Isadora Stéfany Rezende Remigio Mesquita

Entrega: [descrever a ENTREGA: requisitos e produtos gerados: links para textos, códigos, vídeos etc.]

No **Stage 7**, como proposto como objetivo no Gate 5, eu trabalhei na solução de imagética de motora que foi apresentada utilizando outras técnicas. Para isso, alterei os canais que estavam sendo passados para a rede EEGNet. Ao entender melhor o treinamento do modelo em que realizei finetuning, selecionei os mesmos canais que foram passados no treinamento, realizando também um resampling dos dados para manter o formato. No entanto, contrariando as expectativas, não houve melhora. Além disso, realizei um série de pré-processamento nos dados e os submeti a outros algoritmos (SVM e MLP). Mas o resultado também não foi muito diferente.

As minhas orientações quanto aos algoritmos escolhidos partiram tanto de estudos passados quanto do artigo [Influência da Janela de Estimação no Desempenho de Classificação em Sistemas BCI-SSVEP](#), em que ele aborda a respeito de algoritmos de classificação, algumas técnicas de pré-processamento e como a janela de estimação impacta nos resultados. O resumo que escrevi do artigo pode ser encontrado [aqui](#).

Quanto ao desenvolvimento, é possível encontrar aqui: [colab](#)

Por estar conhecendo a limitação dos dados, eu também iniciei o estudo da monografia [Explorando os modelos de difusão em sistemas BCI-SSVEP](#). Neste estudo, são abordados modelos de difusão e como a geração de dados sintéticos têm impactado positivamente os resultados, contribuindo com generalização por meio de modelos generativos, como GANs. Nesse trabalho também são abordados os Classificadores Lineares e SVM.

Planejamento: [descrever o que pretende fazer para realizar a próxima ENTREGA]

Para a próxima semana, irei explorar de forma prática outras técnicas de pré-processamento para aplicação de Imagética Motora e fazer um comparativo com outro dataset.

Observação: [caso precise fazer alguma observação, de qualquer “natureza”]

ACEITE DA ENTREGA:

CEDRIC LUIZ DE CARVALHO: [Go!](#)

RELATÓRIO REFERENTE A ENTREGA DO DIA 07 DE NOVEMBRO DE 2024

Objetivos: Para a próxima Semana, quero colocar em prática a rede estudada e me aprofundar em outro algoritmo da área, como o ShallowConvNet.

1. Estudo da Monografia *Explorando os modelos de difusão em sistemas BCI-SSVEP*:

- 1.1. Nesse contexto, considerando que o desempenho desses sistemas estão muito atrelados ao método de classificação, esse estudo realizou uma revisão do progresso dos métodos de classificação que são baseados em deep learning. Além disso, a técnica de aprendizado profundo possibilita uma alternativa para a classificação de dados em BCIs baseadas em SSVEP e tem recebido enorme visibilidade nos últimos anos. Esse estudo também aborda os modelos das Redes Generativas Adversárias para a criação de dados sintéticos.

2. Leitura do artigo *Influência da Janela de Estimação no Desempenho de Classificação em Sistemas BCI-SSVEP*: o artigo detalha três etapas principais que buscam preparar os sinais de EEG para análise e classificação.

Primeiramente, aborda-se a **remoção de artefatos indesejados** nos sinais, provenientes de movimentos musculares e piscadas, que são filtrados utilizando o método CAR (Common Average Reference). O CAR funciona subtraindo a média dos potenciais de todos os eletrodos a cada amostra, minimizando, assim, a interferência de ruídos comuns. Com isso, os sinais de EEG tornam-se mais precisos para análise, sendo possível focar em informações realmente relevantes para a detecção de respostas neurais.

A etapa de **extração de características** usa a Transformada Rápida de Fourier (FFT), que converte os sinais de EEG do domínio do tempo para o domínio da frequência. Isso permite isolar as frequências de maior potência associadas aos estímulos visuais específicos (frequências SSVEP), facilitando a identificação de padrões de resposta no cérebro. A densidade espectral de potência (PSD) é então calculada para cada frequência, ajudando a destacar as frequências predominantes que correspondem ao estímulo visual aplicado.

Com relação a **seleção de atributos**, uma técnica utilizada para identificar as características mais informativas dos dados. São destacadas duas abordagens principais: a técnica de filtros, que utiliza medidas estatísticas como o coeficiente de correlação de Pearson, e a técnica de wrappers, que emprega métodos iterativos para selecionar atributos relevantes. Embora a seleção de atributos possa melhorar a performance e a capacidade de generalização do classificador, o artigo decide não aplicar essa etapa devido ao alto custo computacional e às

variações que ela pode introduzir, mantendo o foco na comparação de diferentes estruturas de classificação.

Na etapa de **classificação**, o sistema busca categorizar os sinais de EEG conforme os padrões detectados nas características extraídas. Cada sinal de entrada representa um conjunto de atributos associados a uma única saída, ou classe, sendo crucial que o classificador defina fronteiras de decisão precisas entre as classes. Dado o objetivo, duas abordagens são aplicadas: Regressão Logística (RL) e Multilayer Perceptron (MLP).

RL é ideal para casos lineares (detecção de eventos relacionados ao movimento ou uso de sinais P300 para comunicação assistida, por exemplo), ponderando os atributos de entrada para obter uma probabilidade de pertencimento a uma classe específica. A MLP, por outro lado, é utilizada para dados mais complexos em que não há linearidade.

Por fim, o resultado da janela de 1 segundo foi de 81,25% de acerto médio com o MLP, sugerindo que janelas menores exigem classificadores mais robustos para manter o desempenho.

Termo de Aceite de Entrega

Objetivo deste documento

Este documento faz parte do Processo da disciplina Residência em IA e tem como objetivo formalizar o aceite da entrega considerando o planejado e o realizado para o período.

Data da Reunião (“gate”) de aprovação: 14 de nov. de 2024

Participantes da Entrega [matriculados em Residência em IA]:

Isadora Stéfany Rezende Remigio Mesquita

Entrega: [descrever a ENTREGA: requisitos e produtos gerados: links para textos, códigos, vídeos etc.]

No **Stage 8**, como proposto como objetivo no Gate 7, eu trabalhei na solução de intenção motora que foi apresentada utilizando outras técnicas. Para isso, busquei técnicas que permitissem mudar a minha implementação do modelo pré-treinado e do modelo sem pesos. Essa etapa consistiu em buscar entender melhor como foi realizado o pré-treinamento do modelo e tentar adaptar os meus dados ao formato.

Etapa de Pré-processamento

- Conhecimento teórico aplicado na filtragem dos sinais:
- Filtro passa-banda entre 5Hz e 70Hz (preservação das frequências Teta, Alfa, Beta, e Gamma).
- Seleção de canais motores específicos (C3, Cz e C4),

Modelo Pré-treinado

- Abordagem de Classificação do Trial Inteiro com Dados em Janela
- Tentativa de manter 1920 amostras usando janelamento de 200
- Experimentação com interpolação para minimizar a perda de informações
- Ajuste de hiperparâmetros para combater overfitting
- Implementação de callback para ajuste dinâmico do learning rate
- Resultados:
 - F1-Score Público: 67%
 - F1-Score Privado: 74%

Modelo Treinado do Zero

- Abordagem inicial sem janelamento e observação de overfitting
- Ajustes de hiperparâmetros e testes com callback e patience
- Definição de batch (32), kernel (16), e drop_prob (0.5)
- Implementação de janelamento com tamanho de 256 para melhorar generalização
- Resultados:
 - F1-Score Público: 74%

- F1-Score Privado: 68%

O desenvolvimento pode ser encontrado [aqui](#).
Lógica de desenvolvimento [aqui](#).

Planejamento: [descrever o que pretende fazer para realizar a próxima ENTREGA]

Estudar modelos híbridos para aperfeiçoamento da classificação de sinais EEG.

Observação: [caso precise fazer alguma observação, de qualquer “natureza”]

ACEITE DA ENTREGA:

CEDRIC LUIZ DE CARVALHO: Go! ▾

RELATÓRIO REFERENTE A ENTREGA DO DIA 14 DE NOVEMBRO DE 2024

Pré-processamento: realizado com base em conhecimento teórico adquirido durante a residência. Foi aplicado um filtro passa banda, preservando as frequências entre 5Hz e 70Hz, em que se encontram as frequências Teta, Alfa, Beta e Gamma, a fim de não restringir muito a faixa de frequência e comprometer o padrão do dado, dificultando para o modelo compreender. Além disso, foram selecionados 3 canais que são associados a questões motoras (C3, Cz e C4).

Modelo pré-treinado:

Como eu possuía 1920 amostras em cada ensaio e não gostaria de me desfazer de nenhuma delas, busquei entender uma forma de passar essas informações dentro de uma janela de 200 para o modelo. Por isso, optei pela Classificação do Trial Inteiro com Dados em Janela, ou seja, o modelo deveria ver todas as janelas antes de classificar o dado. Porém, a arquitetura da rede pré-treinada não funciona dessa forma. Após muitas tentativas, decidi explorar o modelo sem pesos.

Em seguida, voltei a trabalhar novamente no modelo pré-treinado, mas dessa vez realizando o janelamento com interpolação, tentando perder o mínimo de informações possíveis, embora ainda fosse reduzir a janela para 200. Porém, interpolando ao longo de todo o tempo. Iniciei o treinamento do modelo para ver como seria e nitidamente encontrei o overfitting (também ocorreu no modelo sem pesos). A partir daí, comecei a mexer com hiperparâmetros para lidar com esse cenário.

Além disso, mexi em hiperparâmetros, como também fiz no outro modelo. Dentre os hiperparâmetros, criei uma classe de callback que tem como objetivo ajustar dinamicamente a taxa learning rate do modelo quando o progresso na loss de validação desacelera, ou seja, quando a loss de validação para de melhorar após várias iterações.

F1-Score Público: **67%**

F1-Score Privado: **74%**

Modelo treinado do zero:

Divergente da outra experiência, como eu não gostaria de abrir mão de nenhuma amostra,

os dados foram passados para o modelo, observado o overfitting e os hiperparâmetros começaram a ser mexidos antes do janelamento. Após alterar callback, foi testada uma série de iterações para escolher o melhor valor de patience, que é 5. O batch foi definido como 32 e também foi escolhido com base em experimentos, kernel = 16, drop_prob= 0.5. Porém, ainda podia observar que o resultado apontava um possível overfitting. Por isso, optei por testar o janelamento de 256 que costuma ser muito utilizado.

F1-Score Público: **74%**

F1-Score Privado: **68%**

APÊNDICE 6

Termo de Aceite de Entrega

Objetivo deste documento

Este documento faz parte do Processo da disciplina Residência em IA e tem como objetivo formalizar o aceite da entrega considerando o planejado e o realizado para o período.

Data da Reunião (“gate”) de aprovação: 28 de nov. de 2024

Participantes da Entrega [matriculados em Residência em IA]:

Isadora Stéfany Rezende Remigio Mesquita

Entrega: [descrever a ENTREGA: requisitos e produtos gerados: links para textos, códigos, vídeos etc.]

No **Stage 9**, como proposto como objetivo no Gate 8, eu busquei explorar soluções com modelos híbridos. A fim de manter uma experiência prática, eu me propus a implementar um artigo que tratasse do meu tema foco, a Imagética Motora. Por isso, fiz uma investigação a respeito de diversos artigos, encontrando alguns desafios significativos que conflitavam com os meus objetivos até chegar a um artigo de acordo com os padrões.

Documento com artigos investigados [aqui](#).

O artigo selecionado para implementação foi [Classificação de imagética motora baseada em EEG utilizando árvores de decisão](#). Esse artigo tem como objetivo realizar a classificação de imagética motora binária utilizando classificadores simples e rápidos. Nesse caso, foram experimentadas árvores de decisão, máquinas de vetor de suporte e redes bayesianas. Os dados utilizados nesse artigo são oriundos da Competition IV BCI 2b, no formato .gdf (formato universal para dados fisiológicos). O código de implementação do artigo pode ser encontrado [aqui](#).

Planejamento: [descrever o que pretende fazer para realizar a próxima ENTREGA]

Para a próxima e última Semana, mantereí meu foco em finalizar a implementação do artigo.

Observação: [caso precise fazer alguma observação, de qualquer “natureza”]

ACEITE DA ENTREGA:

CEDRIC LUIZ DE CARVALHO: Go! ▾

RELATÓRIO REFERENTE A ENTREGA DO DIA 28 DE NOVEMBRO DE 2024

Artigos investigados:

1. [Multimodal signal dataset for 11 intuitive movement tasks from single upper extremity during multiple recording sessions](#): Este artigo despertou muito meu interesse devido à sua proposta de trabalhar com sinais multimodais para uma variedade de movimentos. Os autores também argumentam que o conjunto de dados descrito é o primeiro grande repositório público para paradigmas de BCI intuitivos que inclui sinais multimodais, como EEG, EMG e EOG. Além disso, para garantir a aplicabilidade da tecnologia BCI, os pesquisadores planejam investigar como decodificar de maneira robusta intenções motoras, superando desafios como a variabilidade entre diferentes sessões de gravação e a dependência do sujeito (ou seja, os problemas relacionados à variabilidade entre sessões e à independência entre os sujeitos).

No entanto, o conjunto de dados fornecido é extremamente grande, o que torna inviável seu uso em minha máquina devido à limitação de memória e capacidade de processamento. Além disso, os dados contam com 64 canais, o que aumenta significativamente a complexidade de como lidar com essas informações, exigindo um pré-processamento e uma gestão mais eficientes dos dados. Outro fator que dificulta a implementação desse artigo em curto prazo é a necessidade de uma infraestrutura mais robusta, que possa lidar com grandes volumes de dados em tempo real, além de um modelo de decodificação neural que seja capaz de generalizar bem, o que exige um treinamento de longo prazo e muitos recursos computacionais. Esses fatores tornam a reprodução deste trabalho um grande desafio sem a disponibilidade de recursos mais avançados.

2. [An integrated deep learning model for motor intention recognition of multi-class EEG Signals in upper limb amputees](#): Este artigo chamou muito minha atenção devido à sua abordagem inovadora para o reconhecimento de intenções motoras a partir de sinais de EEG, explorando diferentes frequências para aprimorar a classificação. A proposta de integrar LSTM com autocodificadores empilhados (SAE) e otimizar o modelo com t-SNE apresenta um potencial significativo para aplicações em controle protético, especialmente em cenários multiclases e multissujeitos.

Entretanto, implementar esse estudo em apenas duas semanas apresenta desafios substanciais. Primeiramente, os dados de EEG utilizados pelos autores exigem

solicitação, além de um pré-processamento complexo para filtrar ruídos e separar bandas de frequência relevantes. Mesmo que os dados estivessem disponíveis, a integração de múltiplas bandas de frequência no modelo aumenta significativamente a complexidade do pipeline de processamento.

Outro desafio é a necessidade de uma infraestrutura computacional robusta. Treinar o modelo LSTM-SAE com grandes volumes de dados de EEG, aliado ao custo computacional elevado do t-SNE, é inviável em uma máquina comum, devido às limitações de memória e poder de processamento. Adicionalmente, o ajuste de hiperparâmetros do modelo para alcançar o desempenho relatado exige experimentos repetidos, o que consome muito tempo.

Outra observação é que a complexidade do cenário multissujeito e multiclases implica desafios adicionais para lidar com a variabilidade entre indivíduos e garantir separabilidade clara entre as classes.

3. [*EEG-Based Motion Intention Detection for Robotic Rehabilitation: Evaluating Classification and Regression Algorithms*](#): Os robôs de reabilitação têm demonstrado grande potencial para melhorar a recuperação motora em pacientes. A proposta de usar sinais de EEG para determinar a intenção de movimento desejada (DMI) em tarefas de reabilitação é particularmente complexa, pois envolve não apenas o processamento de sinais cerebrais, mas também sua integração com sistemas robóticos para fornecer assistência em tempo real (um grande desafio).

O artigo utiliza técnicas complexas de pré-processamento, exigindo um cuidado minucioso. Além disso, usufrui de algoritmos como redes neurais profundas e floresta aleatória para classificação e regressão, abordando modelos híbridos. Os testes foram realizados em um ambiente controlado com indivíduos saudáveis, o que não reflete as condições reais de reabilitação com pacientes com déficits motores.

A precisão alcançada no estudo, com taxas de até 90% para a classificação entre movimento e repouso, demonstra a eficácia da abordagem, mas reproduzir esses resultados requer experimentação iterativa e acesso a uma infraestrutura computacional robusta, especialmente para lidar com a complexidade do aprendizado profundo.

Por fim, a generalização dos resultados para populações com deficiência motora, que são o público-alvo da tecnologia, implica uma adaptação cuidadosa dos modelos e algoritmos. A limitação de tempo e recursos torna desafiador explorar essas nuances e avaliar completamente a aplicabilidade do sistema em condições reais de reabilitação. Assim, embora o artigo ofereça contribuições valiosas, reproduzir seus resultados em um prazo tão curto apresenta barreiras significativas, principalmente

levando em consideração o gap de retorno do autor para utilizar os dados que ele possui.

4. [Avoidance of specific calibration sessions in motor intention recognition for exoskeleton-supported rehabilitation through transfer learning on EEG data](#): O artigo aborda o uso de **exoesqueletos assistidos** para reabilitação de pacientes com base no reconhecimento de intenções de movimento a partir de **dados de EEG (eletroencefalograma)**. A principal contribuição é uma **abordagem de aprendizado de transferência**, que elimina a necessidade de sessões de calibração prolongadas para treinar modelos individuais de aprendizado de máquina. Os autores propõem treinar classificadores de EEG com dados registrados durante **movimentos bilaterais assistidos** e utilizá-los para prever **movimentos unilaterais**.

Os resultados indicaram que o desempenho do modelo transferido é **comparável ao de modelos não transferidos**, mesmo com o uso de apenas 4 ou 8 canais de EEG. Isso representa um avanço significativo, já que os dados de EEG podem ser registrados diretamente durante as sessões de reabilitação, simplificando o processo e reduzindo os recursos necessários, tornando esse momento mais proveitoso para prática e menos para imaginação motora.

Em estudos futuros, a abordagem será testada em pacientes com AVC, em que movimentos bilaterais serão usados no modo "espelho", onde o braço não afetado guia o movimento assistido do braço afetado. Isso permitirá a **rotulagem automática de dados de EEG** durante as sessões, facilitando o treinamento de classificadores para prever intenções de movimento unilateral. No entanto, os autores destacam que, para pacientes com AVC, a **seleção de canais de EEG** pode precisar de ajustes baseados na lesão.

A pesquisa também sugere que essa nova abordagem pode melhorar a eficácia da **terapia assistida por robôs**, atendendo à crescente demanda de suporte para uma população envelhecida. Isso me deixou muito empolgada, e o conjunto de dados está disponível, mas reconheço que exigiria de mim mais tempo do que eu desejo até concluir as 10 semanas desse processo.

5. [Boosting motor imagery brain-computer interface classification using multiband and hybrid features extraction](#): O artigo propõe uma abordagem híbrida para melhorar a classificação de imagens motoras em sistemas de Interface Cérebro-Computador (MI-BCI). O método combina duas técnicas complementares de extração de características para aumentar a eficiência. A primeira técnica, chamada de Multi-Band Common Spatial Patterns (MBCSP), decompõe os sinais de imagens motoras em várias subbandas de frequência. Para cada subbanda, o método aplica o

Common Spatial Patterns (CSP) para extrair características relevantes, e as bandas específicas de frequência para cada sujeito são então selecionadas.

A segunda técnica, denominada Boosted Tangent Space Mapping (BTSM), utiliza as mesmas bandas de frequência selecionadas pelo MBCSP como entrada para extrair novas características das subbandas. Para otimizar o processo, um algoritmo de seleção automática de características é empregado, permitindo identificar as bandas específicas para cada indivíduo e reduzir a dimensionalidade do espaço de características extraídas.

O modelo proposto foi avaliado utilizando dados de competições públicas, tanto em tarefas multiclasse quanto em tarefas binárias. Entre os conjuntos utilizados estão o Competition IV 2a (22 canais de EEG, 4 classes, 9 sujeitos) e o Competition III 3a (60 canais de EEG, 4 classes, 3 indivíduos) para multiclasse, bem como o Competition III 4a (118 canais de EEG, 2 classes, 5 indivíduos) para classificação binária. Este último foi especialmente desafiador, pois incluiu cenários com poucos dados de treinamento para alguns indivíduos, incentivando o uso de informações de outros sujeitos para melhorar a classificação.

O artigo também destaca o uso do formato GDF (General Data Format for Biomedical Signals), amplamente empregado em estudos de EEG por sua capacidade de armazenar dados multicanais e metadados associados. O artigo também explora os dois principais blocos de uma Interface Cérebro-Computador (BCI) baseada em imagens motoras (MI): o bloco de extração de características e o bloco de classificação. Além de apresentar as abordagens individuais MBCSP-LB e MBBTSM-LB, o trabalho propõe uma nova abordagem híbrida que combina ambas as técnicas de extração de características, integrando-as por meio do classificador LogitBoost.

A técnica MBCSP utiliza filtragem espacial para extrair características de múltiplas subbandas e selecionar as bandas de frequência específicas de cada indivíduo. Já o método BTSM, fundamentado em matrizes de covariância espacial e na geometria Riemanniana, melhora o Tangent Space Mapping (TSM) clássico ao utilizar múltiplos pontos de referência ajustados pelos pesos gerados pelo LogitBoost, em vez de apenas um ponto fixo. Ambos os métodos requerem um bloco de seleção de características: no caso do MBCSP, para identificar as bandas de frequência específicas, e no caso do BTSM, para reduzir a alta dimensionalidade do espaço de características.

O artigo emprega um algoritmo de seleção de características baseado na estimativa de informações mútuas e apresenta critérios para determinar automaticamente o número ótimo de características a serem utilizadas. A abordagem híbrida proposta

(BTSM+MBCSP-LB) foi avaliada em três conjuntos de dados públicos sob cenários de validação cruzada e competição BCI. Os resultados comparativos demonstraram uma melhoria significativa de desempenho, tornando a abordagem híbrida mais robusta do que as técnicas individuais (MBCSP-LB ou BTSM-LB).

Para aplicações futuras em MI-BCI on-line, os autores destacam a necessidade de reduzir o custo computacional da abordagem híbrida, particularmente devido à complexidade da estrutura baseada na geometria Riemanniana. Apesar de fantástico e os dados estarem disponíveis, essa abordagem é extremamente complexa, exigindo um alto grau de investimento de tempo.

Termo de Aceite de Entrega

Objetivo deste documento

Este documento faz parte do Processo da disciplina Residência em IA e tem como objetivo formalizar o aceite da entrega considerando o planejado e o realizado para o período.

Data da Reunião (“gate”) de aprovação: 4 de dez. de 2024

Participantes da Entrega [matriculados em Residência em IA]:

Isadora Stéfany Rezende Remigio Mesquita

Entrega: [descrever a ENTREGA: requisitos e produtos gerados: links para textos, códigos, vídeos etc.]

No **Stage 10**, como proposto como objetivo no Gate 9, eu prossegui com a implementação do artigo [Classificação de imagem motora baseada em EEG utilizando árvores de decisão](#). Ao longo dessa Semana, pude construir o fluxo utilizado pelos autores. Nessa etapa, pude contar com o trabalho do Gustavo dos Reis Oliveira, residente de IA, o qual me auxiliou na seleção dentre os **33 atributos** (extraídos do janelamento dos sinais) estudados por meio do algoritmo de Busca Evolutiva Particle Swarm Optimization (PSO).

A implementação pode ser encontrada [aqui](#).

Planejamento: [descrever o que pretende fazer para realizar a próxima ENTREGA]

Executar o fluxo desenvolvido e extrair métricas para comparação com o artigo.

Observação: [caso precise fazer alguma observação, de qualquer “natureza”]

Gustavo dos Reis Oliveira auxiliou nesta Stage.

ACEITE DA ENTREGA:

CEDRIC LUIZ DE CARVALHO: Go! ▾