

UNIVERSIDADE FEDERAL DE OURO PRETO

Rede de Convolução para Sistema Biométrico baseado em EEG

Thiago Schons
Universidade Federal de Ouro Preto

Orientador: Gladston Juliano Moreira Prates

Coorientador: Eduardo José da Silva Luz

Dissertação submetida ao Programa de Pós-graduação de Ciência da Computação da Universidade Federal de Ouro Preto, como pré-requisito para obtenção do título de Mestre em Ciência da Computação.

Ouro Preto, 11 de abril de 2018

Rede de Convolução para Sistema Biométrico baseado em EEG

Thiago Schons
Universidade Federal de Ouro Preto

Orientador: Gladston Juliano Moreira Prates

Coorientador: Eduardo José da Silva Luz

S363r

Schons, Thiago.

Rede de convolução para sistema biométrico baseado em EEG [manuscrito]
/ Thiago Schons. - 2018.
68f.: il.: color; grafs; tabs.

Orientador: Prof. Dr. Gladston Juliano Prates Moreira.

Dissertação (Mestrado) - Universidade Federal de Ouro Preto. Instituto de Ciências Exatas e Biológicas. Departamento de Computação. Programa de Pós-Graduação em Ciência da Computação.

Área de Concentração: Ciência da Computação.

1. Biometria. 2. Eletroencefalograma. 3. Rede de convolução. 4. Rede neural.
I. Moreira, Gladston Juliano Prates. II. Universidade Federal de Ouro Preto. III.
Titulo.

CDU: 57.087.1



Ata da Defesa Pública de Dissertação de Mestrado

Aos 22 dias do mês de fevereiro de 2018, às 13:30 horas na Sala de Seminários do DECOM no Instituto de Ciências Exatas e Biológicas (ICEB), reuniram-se os membros da banca examinadora composta pelos professores: **Prof. Dr. Gladston Juliano Prates Moreira (presidente e orientador), Profa. Dra. Andrea Gomes Campos Bianchi, Prof. Dr. David Menotti Gomes e Prof. Dr. Vitor Nazário Coelho**, aprovada pelo Colegiado do Programa de Pós-Graduação em Ciência da Computação, a fim de arguirem o mestrando **Thiago Schons**, com o título **“Rede Neural de Convolução para Sistema Biométrico Baseado em EEG”**. Aberta a sessão pelo presidente, coube ao candidato, na forma regimental, expor o tema de sua dissertação, dentro do tempo regulamentar, sendo em seguida questionado pelos membros da banca examinadora, tendo dado as explicações que foram necessárias.

Recomendações da Banca:

Aprovada sem recomendações

Reprovada

Aprovada com recomendações: _____

Banca Examinadora:

Prof. Dr. Gladston Juliano Prates Moreira

Profa. Dra. Andrea Gomes Campos Bianchi

 Prof. Dr. David Menotti Gomes

Prof. Dr. Vitor Nazário Coelho

Certifico que a defesa realizou-se com a participação à distância do membro Prof. Dr. David Menotti Gomes, depois das arguições e deliberações realizadas, o participante à distância está de acordo com as recomendações da banca examinadora.

Prof. Dr. Gladston Juliano Prates Moreira

Prof. Dr. Anderson Almeida Ferreira
 Coordenador do Programa de Pós-Graduação em Ciência da Computação
 DECOM/ICEB/UFOP

Ouro Preto, 22 de fevereiro de 2018.

Dedico este trabalho para meus pais, irmãos, sobrinhos e minha namorada, que são meu alicerce, acreditam em mim e estão sempre me apoiando e me fazendo acreditar que sonhos são para serem vividos. Espero compartilhar muitas realizações com todos vocês, pois é isso que me move.

Resumo

Sistemas biométricos encontram-se em grande expansão pela necessidade de segurança em todas as esferas da sociedade, nesse contexto sistemas baseados em eletroencefalograma (EEG) vem despertando grande interesse entre os pesquisadores. No entanto, essa modalidade biométrica é suscetível a ruídos na captação de sinais e tem problemas de escala, acurácia e captação em ambientes não controlados, representando um grande desafio. Métodos baseados em redes neurais de convolução vêm sendo explorados na literatura para processamento de sinais e resultados expressivos para sua classificação vem sendo obtidos. Nesse cenário, o método proposto neste trabalho é baseado em Rede Neural de Convolução (CNN) para verificação biométrica e avaliação em uma base de dados da *Physionet*. Uma técnica de *data augmentation* baseada em sobreposição dos sinais é proposta para ampliar a quantidade de dados de treinamento da rede de aprendizagem em profundidade. A redução do *equal error rate* (EER) de 4,5% para 0,19% nos testes *baseline* em comparação com a literatura mostram que o método é um caminho promissor na representação de sinais cerebrais para biometria.

Palavras-chave: Redes Neurais de Convolução, Biometria, EEG, Eletroencefalograma, CNN, Modo de Verificação, Data Augmentation.

Abstract

Biometric systems are in great expansion by the need for security in all spheres of society, in this context systems based on electroencephalogram (EEG) has aroused great interest among researchers. However, this biometric modality is susceptible to noise in signal capture and has problems of scale, accuracy and capture in uncontrolled environments, representing a great challenge. Methods based on convolution neural networks (CNN) have been explored in the literature for signal processing and expressive results for their classification have been obtained. In this scenario, the proposed method is based on CNN for biometric verification and evaluation in a *Physionet* database. A data augmentation technique based on overlapping signals is proposed to increase the amount of training data for the deep learning network. The reduction of the equal error rate (EER) from 4.5% to 0.19% in the baseline tests compared to the literature shows that the method is a promising path in the representation of brain signals for biometrics.

Keywords: Convolutional Neural Networks, Biometry, EEG, electroencephalogram, CNN, Verification Mode, Data Augmentation.

Agradecimentos

Gostaria de agradecer a Deus, por permitir essa oportunidade de aprendizado e crescimento.

Quero agradecer também meus orientadores Gladston Moreira Juliano Prates e Eduardo José da Silva Luz, pela paciência, empenho e dedicação. Confiaram em mim e permitiram que este trabalho se concretizasse sem nunca terem economizado esforços para transmitir conhecimento.

A meus pais e irmãos, que são meu porto seguro e estão sempre me dando apoio incondicional, sem eles não conseguiria chegar onde estou.

A minha namorada Adriana que fez parte de tudo, me acompanhou nos momentos bons e difíceis, do início ao fim dessa jornada. Me motivou sempre e acreditou no meu potencial encarando tudo sempre com muito amor.

A meus amigos e colegas que participaram deste processo, me incentivando, enviando energia positiva sempre e acreditando que isso tudo seria possível.

Agradeço também a UFOP e as agências de fomento Capes, CNPq e FAPEMIG.

Sumário

Lista de Figuras	x
Lista de Tabelas	xi
1 Introdução	1
1.1 Objetivos	4
1.2 Estrutura	4
2 Fundamentação Teórica	5
2.1 Pré-Processamento de Sinais	5
2.2 Biometria	6
2.2.1 Conceitos de Biometria	7
2.3 Aprendizado em Profundidade	10
2.3.1 Redes Neurais de Convolução	11
2.4 Data Augmentation	15
2.5 Base de Dados Physionet	16
3 Revisão da Literatura	19
3.1 Estado de Repouso com EO e EC	19
3.2 Multitarefa	22

4	Rede Neural de Convolução para Biometria Baseada em EEG	25
4.1	Pré-Processamento	25
4.2	Processamento Dos Dados	26
4.2.1	Divisão dos Dados de Entrada	26
4.2.2	Data Augmentation	27
4.3	Rede Neural de Convolução	29
5	Experimentos e Discussões	31
5.1	Características da Base de Dados	31
5.2	Experimentos	32
5.2.1	Discussão de Resultados	34
6	Conclusões e Trabalhos Futuros	39
A	Apêndices	41
A.1	Publicações	41
	Referências Bibliográficas	50

Lista de Figuras

2.1	Curva DET com a relação entre FAR, FRR e EER. Extraída/adaptada de (Du and Chang 2007).	10
2.2	Operações de uma rede neuronal convolucional de 3 camadas. Extraída/adaptada de (Pinto and Cox 2011).	12
2.3	Sinal de EEG do eletrodo FC5 amostrado em 10 segundos.	17
2.4	Posição dos eletrodos na região do escalpo. Fonte: http://physionet.org/pn4/eegmmidb/	17
3.1	Eletrodos utilizados por (Tangkraingkiy et al. 2009).	21
4.1	Exemplo de distribuição dos segmentos de EEG usados para treino em EO e teste em EC.	27
4.2	<i>Data augmentation</i> com janela deslizante de tamanho 12 segundos. Temos em a) janela na posição <i>offset</i> 0, primeiro segmento criado. b) <i>offset</i> de 5 segundos. c) <i>offset</i> de 10 segundos e d) último segmento criado, após a janela deslizar sobre todo o sinal.	28
4.3	Modelo <i>deep learning</i>	30
5.1	Curva DET para os experimentos propostos testando as faixas de frequência.	35
5.2	Curvas DET dos resultados satisfatórios obtidos com o uso de tarefas.	37

Lista de Tabelas

3.1	Quantidade de eletrodos utilizados e acurácia obtida. Extraída/Adaptada de (Singh et al. 2015).	21
4.1	Faixa de frequências normalmente utilizadas em EEG.	26
5.1	Arquitetura proposta para biometria com EEG.	33
5.2	Distribuição dos <i>learning rates</i> durante as épocas de treino.	34
5.3	EER obtido de faixas de frequências específicas.	35
5.4	Comparação com trabalhos relacionados.	36
5.5	Resultados expressos em termos de EER com o uso de tarefas.	36
5.6	Comparação com trabalhos relacionados multitarefas.	38

“Não existe um caminho para a felicidade, a felicidade é o caminho”
— Mahatma Gandhi

Capítulo 1

Introdução

Atualmente a humanidade em todas suas esferas, necessita de segurança, sendo a evolução de sistemas biométricos, de fundamental importância para proteção de informações e acesso a locais restritos. A biometria se caracteriza por necessitar da apresentação de alguma característica humana, seja ela comportamental ou biológica. Para uma característica ser modalidade biométrica devem ser atendidos 4 requisitos: coletividade, distinção, permanência e universalidade (Clarke 1994, Jain et al. 2004).

A tecnologia está evoluindo muito nos últimos anos e assim como os sistemas de segurança, também evoluem técnicas de invasão. Nesse contexto, os sistemas biométricos também estão em evolução constante, porém formas de captura de características robustas e discriminantes entre pessoas são desejáveis, principalmente para novas formas de biometria.

O presente trabalho lida com o uso dos sinais do eletroencefalograma (EEG) para a tarefa biométrica. O sinal de EEG é a medida da atividade elétrica cerebral por meio de eletrodos posicionados na região do escalpo em posições estratégicas. A medida é feita com base no somatório de pequenos impulsos elétricos que são emitidos pelos neurônios (Boubakeur et al. 2017). As faixas cerebrais podem ser divididas em faixas de frequência, e as mais relevantes de EEG estão relacionadas as bandas: Delta (0.5, 40 Hz), Theta (4-8 Hz), Alpha (8-14 Hz), Beta (14-30 Hz) e Gamma (> 30 Hz).

O EEG é uma modalidade biométrica muito segura se comparada a formas de biometria tradicionais, visto que os sinais mudam conforme o sujeito executa determinada tarefa, pois é sensível a mudança de emoções e pensamentos, mudando as interconexões de neurônios, e instantaneamente mudando também o campo elétrico cerebral (Soni

et al. 2016). Isso torna a biometria mais flexível em caso de ataque ao banco de dados, pois se os dados forem roubados, como no caso da impressão digital, iris ou qualquer característica física, estas informações deveriam ser descartadas, por motivo de segurança (Boubakeur et al. 2017). Usando deste artifício, a biometria baseada em EEG torna-se mais efetiva, pois a mesma modalidade pode ser reutilizada, somente alterando a tarefa designada para o indivíduo e recadastrando os dados biométricos no banco de dados, mudando assim os sinais de EEG e impossibilitando o uso de dados roubados, fornecendo assim mais integridade e autenticidade (Boubakeur et al. 2017)

A biometria por EEG é promissora quando analisada de uma perspectiva futura, mas tem uma grande limitação atualmente, que são os dispositivos para aquisição dos dados. Os sensores evoluíram muito nos últimos anos e em paralelo ficaram e estão ficando mais baratos, porém o tempo de preparação e a necessidade de pessoal qualificado para manuseio das máquinas de coleta ainda são um empecilho. A impedância gerada entre couro cabeludo e os eletrodos tem que ser reduzida com o uso de gel condutor com o intuito de aumentar a qualidade do sinal (Ma et al. 2015).

O primeiro sistema biométrico baseado em EEG foi introduzido por (Stassen 1980). Utilizando classificação do espectro de EEG, eles conseguiram obter 90% de probabilidade de confiança analisando dados de 82 sujeitos. Posteriormente, (Poulos et al. 1999b) mostrou a viabilidade na utilização de sinais de EEG para tarefas biométricas, e desde então, o interesse da comunidade científica nesse ramo da biometria aumentou. Muitas abordagens fazendo uso de EEG foram propostas, como em (Fraschini et al. 2015), que realizou a tarefa de verificação biométrica em cima da base de dados de EEG *Physionet* (Goldberger et al. 2000) (também utilizada no presente trabalho). Nessa base existem sinais de sujeitos em estado de repouso e é feita uma análise em dois cenários: olhos abertos (EO) e olhos fechados (EC). Os autores fizeram um estudo sobre as faixas de frequência comumente empregadas e constaram que a faixa *gamma* (30-50 Hz), onde foi reportado um *equal error rate* de 4,4% é mais discriminante que as outras. A abordagem é baseada em sincronização de fases, na qual o *Eigenvector Centrality* é obtido a partir de cada nó (sujeito) que está inserido na rede para compor o vetor de características e então efetuar a classificação.

No trabalho proposto por (Yang et al. 2016), são consideradas quatro tipos de tarefas, em que os sujeitos realizam tarefas motoras ou imaginárias durante a gravação dos sinais e somente nove dos 64 eletrodos foram escolhidos para participar dos experimentos. A base de dados da *Physionet* é considerada e uma mistura de dados de treino a teste são feitos a partir das quatro tarefas, em diferentes seções. O *equal error rate* (EER)

encontrado usando 9 eletrodos foi 4,5%.

Muitas técnicas de *machine learning* e reconhecimento de padrões já foram utilizadas visando identificar indivíduos por meio de sinais de EEG, porém não há muitas abordagens utilizando rede neural de convolução. (Ma et al. 2015) propôs uma rede neural de convolução (CNN) com 5 camadas, sendo duas de convolução, dois *pooling* e finalmente, uma camada *fully connected*. A análise da rede é feita na base de dados da *Physionet*, utilizando dados de 10 indivíduos, dividindo 55 segundos de gravação em fragmentos de 1 segundo cada. Os testes foram executados com dados dos indivíduos em estado de repouso com olhos abertos, olhos fechados e ambos. O modo biométrico utilizado é verificação.

Já em (Das et al. 2017), os autores coletaram dados de EEG de 40 indivíduos em duas sessões divididas em duas semanas, utilizando 19 eletrodos e estímulos alvo (*target*) e não-alvo (*not-target*) a partir de estímulos visuais com figuras geométricas onde o círculo é o estímulo alvo, e o restante deve ser ignorado pelo indivíduo e o observador deve prestar atenção somente nele. A CNN contém 4 camadas de convolução, 2 *max-pooling*, 1 camada de ativação *ReLU*, uma camada de perda e uma *fully connected*. Outra abordagem relacionada a CNN para sistema biométrico com EEG é encontrada em (Mao et al. 2017) para teste em uma rede de 100 indivíduos, os autores utilizaram uma arquitetura de rede descrita em (Cecotti et al. 2014). Ambos os trabalhos executam biometria pelo modo de identificação.

Os protocolos de testes utilizados pelas abordagens baseadas em CNN para EEG (Das et al. 2017, Ma et al. 2015, Mao et al. 2017), usam bases de dados e abordagens diferentes, não permitindo comparações. O único que permitiria comparações é o trabalho de (Ma et al. 2015), contudo, foram utilizados somente dados de 10 indivíduos, dos 109 disponíveis e usando o modo biométrico de identificação, inviabilizando comparações.

No geral, o procedimento comum de biometria envolve a coleta de dados, extração de recursos de pré-processamento e reconhecimento de padrões (Palaniappan and Mandic 2007b).

Neste trabalho, os resultados alcançados mostram que o uso de CNN para biometria com EEG é um caminho promissor, pois conseguiu resultados que superaram trabalhos considerados estado-da-arte em verificação, como os trabalhos de (Fraschini et al. 2015) e (Yang et al. 2016), reduzindo o EER de 0,19% para EO-EC e para 0,08% usando tarefas.

Parte desta dissertação foi publicada no vigésimo segundo CIARP (*Iberoamerican Congress on Pattern Recognition*), evento que aconteceu na cidade de Valparaíso, Chile, em novembro de 2017, com o artigo intitulado ” *Convolutional Network for EEG-Based Biometric*” (Schons et al. 2018). O artigo pode ser encontrado na Seção A.1.

1.1 Objetivos

O objetivo do presente trabalho é propôr uma representação do sinal de EEG baseada em *deep learning* para a tarefa biométrica de verificação. A técnica *data augmentation* é explorada para aumentar a quantidade de dados do conjunto de treino para suprir a demanda da rede neural de convolução.

Pode-se definir ainda como objetivos específicos do trabalho:

- Investigar o uso de CNN para biometria baseada em EEG.
- Investigar o uso de *data augmentation* para multiplicação de instâncias de treino.
- Analisar o uso de diferentes faixas de frequência nos testes *baseline*.
- Verificar o comportamento de diferentes cenários de treino e teste, usando os dados disponíveis da *Physionet*.

1.2 Estrutura

O restante do trabalho é organizado da seguinte forma: O Capítulo 2 apresenta fundamentação teórica, de leitura imprescindível para entendimento do restante da dissertação. O Capítulo 3 contém revisão bibliográfica de trabalhos da literatura considerados fundamentais para o entendimento de sistemas biométricos e também EEG. No Capítulo 4 é apresentada a metodologia proposta. No Capítulo 5 são mostrados os resultados experimentais e discussão acerca disso. Finalmente, no Capítulo 6 são apresentadas as conclusões.

Capítulo 2

Fundamentação Teórica

Este capítulo apresenta a base teórica dos temas abordados na dissertação e é organizado da seguinte forma: A Seção 2.1 apresenta uma discussão sobre pré-processamento de sinais. A Seção 2.2 trata dos conceitos básicos sobre biometria, a Seção 2.3 sobre aprendizado em profundidade e redes neurais de convolução. A Seção 2.4 explica a técnica de *data augmentation*. e finalmente, a Seção 2.5 explica a base de dados da *Physionet*, de onde surgiu e quais são os objetivos da mesma. A familiarização do leitor com esses conceitos é de fundamental importância para o entendimento do trabalho como um todo.

2.1 Pré-Processamento de Sinais

Os sinais de EEG enfrentam um grande desafio na sua captação, pois há muitas limitações nos sensores que efetuam a extração de características cerebrais de pessoas. Dados brutos de EEG são vulneráveis à contaminação por diversos ruídos, entre estes estão: atividades elétricas de movimentos corporais, ruído térmico e batimentos cardíacos. A extração também passa por limitações como a propagação do sinal por camadas da cabeça, tal como osso e couro cabeludo. A interação entre os sensores e os sinais também representam barreiras por gerar impedância, que é reduzida com uso de gel condutor (Ma et al. 2015).

Como o EEG fornece informações de diversas aplicações, sejam biométricas, para detecção de doenças, e inúmeras outras o pré-processamento de sinais para eliminar informações desnecessárias é fundamental, visando prover somente as características

mais discriminantes em cada área, melhorando consequentemente sua eficácia.

Normalmente, para aplicações biométricas, filtros passa-banda são aplicados para processar somente as faixas mais relevantes para aplicação de biometria, pois cada faixa de frequência está associada à uma atividade cerebral (Boubakeur et al. 2017).

O algoritmo *common spatial pattern* (CSP) separa um sinal multivariante em sub-componentes aditivos que contém diferenças máximas de variância entre duas janelas, encontrando filtros espaciais que são úteis para discriminar diferentes classes de sinais de eletroencefalograma. No entanto, este algoritmo é sensível a *outliers* e para melhorar esse problema, em (Yong et al. 2008) propuseram uma modificação no algoritmo, substituindo estimativas de covariância clássicas pela covariância adquirida pelo estimador de covariância mínima (MCD).

Abordagens como aplicação de algoritmo de identificação de componentes independentes (ICA) no domínio da frequência com algoritmos bastante utilizados na literatura são apresentados em (Delorme et al. 2006). Os algoritmos apresentados são: Infomax, SOBI e FastICA. No domínio do tempo (Sadasivan and Dutt 1995) fez uso do algoritmo FIR de passa-baixa digital de fase linear para atenuar interferências a partir de sinais de EEG contaminados.

Transformadas *Wavelet* foram usadas com um filtro adaptativo através do algoritmo RLS para reduzir artefatos no sinal de EEG por (Kumar et al. 2009) e uma combinação do algoritmo *fastICA* e a transformada discreta *Wavelet* é proposta por (Ghandeharion and Ahmadi-Noubari 2009) com a mesma finalidade.

Existem muitos algoritmos de pré-processamento de sinais em aplicações que necessitam de refinamento nos sinais para extração de informações. Nesta dissertação, são aplicados filtros passa-banda afim de permitir somente sinais de uma faixa intermediária, atenuando os que estejam acima ou abaixo das frequências pré-estabelecidas. Assim como no trabalho de (Fraschini et al. 2015), algumas bandas de frequência foram selecionadas para filtragem, porém com limites diferentes.

2.2 Biometria

Atualmente, em todas as esferas da nossa sociedade tem-se uma grande necessidade de segurança, visto que as formas de fraude evoluem gradativamente a cada dia, principalmente quando estão envolvidas informações e valores monetários. Nesse contexto,

sistemas biométricos também devem estar em constante evolução, prevenindo acesso de indevidos em qualquer local restrito e para isso exigem robustez associado à boa acurácia, tanto para ambientes controlados como em ambientes não controlados. A atenção da comunidade de pesquisadores vem aumentando e novas formas de biometria vão surgindo, cada vez mais eficientes e com maior segurança.

Formas de biometria tradicionais como impressão digital (Batool and Tariq 2011) e face (K. et al. 2009) são mais difundidas atualmente, porém novas tecnologias de extração de características estão sendo desenvolvidas e assim surgem sistemas biométricos providos de novas fontes, tais como: iris, áudio, sinais vitais, marcha, eletrocardiograma, e eletroencefalograma.

O desenvolvimento de sensores de captação de sinais biométricos e a redução de custo dos mesmos auxilia muito no progresso de estudos da biometria, tornando os equipamentos mais acessíveis a todos os âmbitos da sociedade, incluindo as comunidades de pesquisas relacionadas.

2.2.1 Conceitos de Biometria

Para um sistema ser qualificado como biométrico deve ser composto por qualquer característica física ou comportamental que é denominada modalidade biométrica e tem que satisfazer uma série de requisitos, que segundo (Jain et al. 2004) são:

- Universalidade: Toda e qualquer pessoa deve ter a característica;
- Distinguível: Deve ser capaz de permitir a diferenciação entre quaisquer seres humanos;
- Imutável: A característica deve ser invariante em relação ao tempo;
- Mensurável: Deve ser medida e quantificada de alguma forma;

De acordo com (Lumini and Nanni 2017), diferentes sistemas biométricos seguem um mesmo padrão que é composto por 4 componentes:

1. Módulo de Aquisição: Neste módulo são capturados os dados referentes a biometria do indivíduo, sendo cada modalidade biométrica com os equipamentos adequados.

A qualidade da captura depende de diversos fatores, tais como o ambiente e a qualidade dos sensores que irão captar os dados biométricos. O módulos de aquisição impactam diretamente no desempenho de sistemas, portanto, quanto maior a qualidade, melhores serão os resultados.

2. Módulo de Extração de Características: Os dados podem passar por um pré-processamento para remoção de ruídos e então pelo processo de extração de recursos, que consiste em extrair características discriminativas entre um indivíduo e outro. A partir disso, uma representação será chamada de instância e a modalidade biométrica de vetor de características.
3. Módulo de Comparação: Efetua comparações entre os vetores de características gerando um grau de similaridade para cada par de dados biométricos. Este grau deve ser alto para características da mesma pessoa e baixa para pessoas distintas.
4. Módulo de Decisão: Neste módulo a identidade é aceita ou rejeitada, com base nos graus de similaridade do módulo de comparação, ou seja, verifica se o indivíduo é quem ele proclama ser, ou se pertence a um certo grupo de indivíduos.

Ainda de acordo com (Lumini and Nanni 2017), um sistema biométrico é basicamente um sistema de reconhecimento de padrões, onde são adquiridos dados biométricos de um indivíduo e comparado a um conjunto de dados armazenados no banco de dados. E dependendo do contexto o sistema biométrico pode operar nos modos de registro, verificação ou identificação, como descritos a seguir.

1. Modo de Verificação: Neste modo, o usuário fornece sua identificação por meio de uma modalidade biométrica e o sistema é responsável por efetuar a validação caso o indivíduo seja quem ele proclama ser, em outras palavras, o sistema compara com informações presentes no banco de dados, referentes à identidade previamente informada ao sistema. O modo de verificação é também conhecido como identificação positiva (na qual o propósito é dar acesso exclusivo a somente uma pessoa), algumas aplicações mais difundidas são as senhas alfanuméricas e cartões de reconhecimento.

$$(X_1, X_2) \in \begin{cases} \textit{genuino}, & \text{se } S(X_1, X_2) \geq t \\ \textit{impostor}, & \text{caso contrário} \end{cases} \quad (2.1)$$

A tarefa de verificação pode ser modelada pela Equação 2.1, onde S é a função que mede a similaridade entre dois vetores de características (X_1 e X_2), essa medida é feita utilizando distância euclidiana e t é um limiar predefinido (Jain et al. 2004). A identidade de uma pessoa é reivindicada e classificada como genuína quando os pares são semelhantes e impostor caso contrário. Depois disso, as curvas de distribuição genuínas (intra-classe) e impostor (inter-classe) são geradas a partir de pontuações de similaridade.

2. Modo de Identificação: O modo de identificação consiste em verificar se um indivíduo é pertencente a um grupo de indivíduos. Neste sistema, a identidade não é previamente fornecida e, portanto, a informação de entrada é comparada com todas as outras identidades armazenadas no banco de dados num esquema um-para-muitos.

$$(X_q) \in \begin{cases} I_k, & \text{Se } \max_k S(X_{I_q}, X_{I_k}) \geq t, k = 1, 2, \dots, N \\ I_{N+1}, & \text{caso contrário} \end{cases} \quad (2.2)$$

A formulação matemática por dissimilaridade pode ser expressa pela Equação 2.2, na qual X_q é o vetor de características, I_k é a identidade a ser comparada as outras no banco de dados ($k \in 1, 2, \dots, N, N + 1$). Se o vetor não combinar com algum dos vetores armazenados no banco de dados, será considerado do tipo $N + 1$, ou não pertencente ao grupo.

3. Modo de Registro: O modo registro é para inserção de um novo indivíduo no banco de dados, ou seja, um primeiro contato com o sistema biométrico. A captura é feita por sensores e os dados são representados por alguma técnica de extração de características.

Em geral, a grande maioria dos trabalhos de biometria com EEG se dão no cenário de identificação, e diversos autores reportam 100% de reconhecimento (vide Capítulo 3) de indivíduos, isso se dá devido a carência de um protocolo experimental, dificultando a comparação de resultados. Inicialmente, a referencia base do presente trabalho é o artigo apresentado em (Fraschini et al. 2015) que utiliza um protocolo rígido, baseado em verificação. O protocolo é reprodutível e mais adequado para efeitos comparativos entre trabalhos da literatura. Ainda, este protocolo é desafiador pois há grande dificuldade em obter desempenhos próximos da otimalidade.

O processo de verificação é utilizado para realizar a biometria, para medir o desempenho do método proposto é utilizado o *equal error rate* (EER), e por meio das curvas DET ou *Detection Error Trade-Off*, que é um gráfico onde mostra a relação entre dois tipos de erro, a taxa de falsa aceitação (FAR) e a taxa de falsa rejeição (FRR).

O EER é definido como o ponto em que a FAR é igual a FRR. As curvas FARs e FRRs são originados a partir da comparação de pares intra-classe e inter-classes. Já a curva DET é formada por meio de comparação das instâncias do conjunto de teste, num esquema todos contra todos, para a tarefa de verificação. Na curva DET é plotada a taxa de erro nos dois eixos, fornecendo tratamento uniforme para os tipos de erros amostrados, e é utilizada uma escala para ambos os eixos, que efetua uma difusão do gráfico, melhorando a distinção de diferentes sistemas com bom desempenho (Martin et al. 1997). Na Figura 2.1 é possível a visualização da relação das taxas de erro e o ponto onde encontra-se o EER.




Figura 2.1: Curva DET com a relação entre FAR, FRR e EER. Extraída/adaptada de (Du and Chang 2007).

2.3 Aprendizado em Profundidade

O aprendizado em profundidade, busca em sua essência, imitar a robustez e eficiência da representação e aprendizagem de informações do cérebro humano. A forma como o cérebro interpreta informações, as colhe conforme o ambiente em que está inserido,

processa e armazena dados para possível uso no futuro é algo almejado para o ramo de inteligência artificial e, inclusive, há razões para acreditar que o sistema visual humano contém modelos generativos de múltiplas camadas (Felleman and Essen 1991, Lee et al. 1998).

Os primeiros modelos de aprendizagem em profundidade foram usados para reconhecimento de objetos individualmente em imagens cortadas e extremamente pequenas (Hirose et al. 1991). A partir disso, houve incremento no tamanho das imagens utilizadas e na capacidade de processamento das redes neurais.

O aprendizado em profundidade está sendo amplamente utilizado, por sua gama enorme de aplicações e obtenção de bons resultados, o processo de aprendizado pode ser supervisionado, semi-supervisionado ou não supervisionado. A identificação das abstrações nos dados é o foco das arquiteturas que efetuam a implementação do *Deep learning*, iniciando por um nível de abstração baixa dos dados, até um alto nível, que corresponde as camadas mais profundas da rede, conseguindo obter um alto índice de abstração.

O aprendizado em profundidade produz modelos generativos de características, portanto a classificação obtida por uma rede de aprendizagem em profundidade pode ser também classificada por outros modelos generativos (Rumelhart et al. 1986).

O aprendizado supervisionado com a utilização de *Deep learning* evoluiu muito com o passar dos anos, alcançou desempenho superior às técnicas convencionais de aprendizado de máquina. Inclusive, desafios como o ImageNet, que é um desafio tradicional de reconhecimento visual em grande escala obteve como vencedor uma técnica de *deep learning* (Krizhevsky et al. 2012).

A rede neural de convolução (*convolutional neural network (CNN)*), é uma das técnicas mais populares e promissoras da comunidade de *deep learning*, por esse motivo ela foi escolhida para ser investigada nesta dissertação.

2.3.1 Redes Neurais de Convolução

As redes neurais de convolução (LeCun et al. 1989), que também são conhecidas por redes neurais convolutivas, ou CNN, são um tipo especializado de redes neurais para processamento de dados e possuem uma topologia conhecida e semelhante a uma grade. Estas redes tem imenso sucesso em aplicações práticas que envolvem visão computaci-

onal. O nome rede neural de convolução indica uma operação matemática denominada convolução. A convolução é um tipo especializado de operação linear e redes convolutivas são basicamente nós em camadas que fazem uso da convolução ao invés da multiplicação da matriz geral em pelo menos uma de suas camadas.

O processo de uma rede neuronal convolucional tal como descrito em (Pinto and Cox 2011) é ilustrado pelo diagrama da Figura 2.2. Em resumo as redes neuronais convolucionais são compostas de múltiplas camadas, onde cada uma delas realiza um processo de filtragem por um banco de *kernels*(convolução), ativação, *pooling* e normalização.

A camada de convolução tem por objetivo extração de características por meio da operação de convolução da amostra de entrada com um *kernel*. A camada de ativação tem o importante papel de aprimorar a robustez da rede, retificando a saída da amostra convoluída, descartando informações menos importantes. O pooling é uma operação que tem como objetivo adicionar capacidade de invariância a translação, por meio de operações, como máximo ou média, de determinadas regiões da amostra. Por fim, a camada de normalização promove uma competição entre os filtros, forçando sempre o uso de filtros com a melhor resposta, de acordo com um critério.

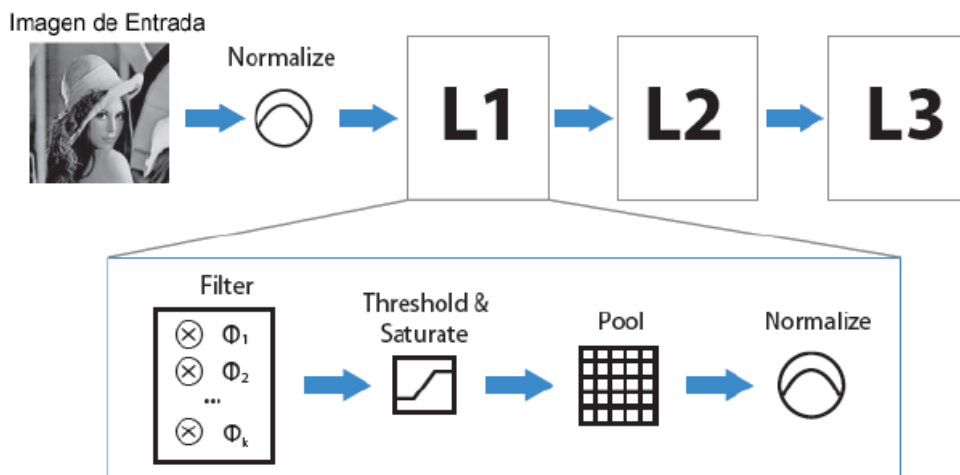


Figura 2.2: Operações de uma rede neuronal convolucional de 3 camadas. Extraída/adaptada de (Pinto and Cox 2011).

A princípio, na camada 0 (inicial), a amostra, ou padrão de entrada, a ser processada é normalizada:

$$\text{Camada 0: Entrada} \xrightarrow{\text{Normalização}} N^0$$

e então, as demais camadas são processadas, *i.e.*, $\forall j \geq 1$

$$\text{Camada } j : N^{j-1} \xrightarrow{\text{Filtragem}} F^j \xrightarrow{\text{Ativação}} A^j \xrightarrow{\text{Pooling}} P^j \xrightarrow{\text{Normalização}} N^j$$

A entrada para o processo de Filtragem é uma amostra N^{j-1} . Esta amostra é filtrada utilizando um banco de k^j filtros denotado por Φ^j para gerar uma amostra multi-banda com k^j bandas denotado por F^j . Cada banda da amostra multi-banda F^j é dado por:

$$F_i^j = N^{j-1} \circ \Phi_i^j \quad \forall i \in \{1, 2, \dots, k^j\}$$

onde \circ denota a operação de convolução sobre a saída da camada anterior N^{j-1} com o filtro Φ_i^j . De fato os filtros de Φ^j tem três dimensões, onde a terceira dimensão é igual ao número de bandas da saída da camada anterior, *i.e.*, k^{j-1} . O processo de filtragem tem os seguintes parâmetros:

- O tamanho dos filtros tridimensionais $f_s^j \times f_s^j \times f_d^j$, onde $f_d^j = k^{j-1}$
- O número de filtros k^j na camada j

No método proposto em (Pinto and Cox 2011), todos os filtros são gerados aleatoriamente com uma distribuição uniforme, média 0 e norma 1. Já em (LeCun et al. 1998), os coeficientes dos filtros são aprendidos por meio de um processo supervisionado.

Uma função de ativação é aplicada sob as saídas do processo de filtragem, de forma que os valores da saída são ajustados a um intervalo determinado, tal como:

$$\text{Ativação}(x) = \begin{cases} 1 & \text{Se } x < 0. \\ 0 & \text{Caso contrário.} \end{cases} \quad (2.3)$$

Este processo de ativação visa justamente imitar a função de um neurônio que tem seu sinal de saída ativado apenas se uma determinada quantidade de energia é recebida.

O processo de *pooling* é aplicado sobre a amostra multi-banda de ativação A^j . Esta operação é definida como:

$$P^j = \text{Subamostragem}_\alpha(\sqrt[p^j]{(A_i^j)^{p^j} \odot I(a^j \times a^j)}) \quad (2.4)$$

onde \odot é uma correlação bidimensional, $I(a^j \times a^j)$ é uma matriz de 1's de $a^j \times a^j$, a variável p^j controla o expoente do *pooling*. Esta operação tem os seguintes parâmetros:

- O *stride* α por exemplo, se fosse 2 a subamostragem seria por fator de 4
- O tamanho de vizinhança de *pooling* a^j
- O expoente p^j

Logo a saída do *pooling* é normalizada com seus vizinhos. A operação de normalização é definida como:

$$N^j = \frac{P^j}{\|P^j \otimes I(b^j \times b^j \times k^j)\|} \quad (2.5)$$

onde \otimes é a operação de correlação em três dimensões e $I(b^j \times b^j \times k^j)$ é uma matriz de 1's de $b^j \times b^j \times k^j$ e b^j é o tamanho da vizinhança quadrangular na operação de normalização.

Esta operação de normalização também é bio-inspirada a partir da interação competitiva observada em sistemas neuronais naturais (*e.g.*, mecanismo controle de ganho de contraste na área cortical V1 e em outros lugares (Geisler and Albrecht 1992, Rolls and Deco 2002)) e é muito importante para o aprendizado das representações.

Um grande problema que atinge as redes neurais de convolução de maneira geral, é o *overfitting*, e o *dropout* é uma técnica criada para ajudar a impedi-los, esta técnica consiste em excluir algumas unidades (ocultas ou visíveis) aleatoriamente, a partir de uma probabilidade p , com o intuito de evitar co-adaptações complexas nos dados de treinamento criado pelo aprendizado padrão do *backpropagation* usado na CNN (Hinton et al. 2012).

2.4 Data Augmentation

Atualmente, com a grande eficácia e difusão de técnicas de aprendizado em profundidade para aplicações práticas, sua utilização está em expansão, porém é de conhecimento comum, para que funcionem e generalizem bem o problema de estudo, deve-se ter grande quantidade de dados de qualidade disponíveis para treinamento, caso contrário poderá acarretar em *overfitting* e não convergência no modelo por escassez de dados de treinamento. No entanto, é difícil encontrar bases de dados com grande quantidade de dados de qualidade, a não ser para a modalidade de face, que tem bases de dados extensas disponíveis.

Técnicas de *data augmentation* estão sendo propostas para superar o problema da escassez de dados, esta técnica pode ser feita de diversas maneiras, e com maior facilidade em problemas de visão computacional, pois pode-se gerar dados novos com muita facilidade através de manipulações de imagem, como mudança no escalonamento, rotação e outras transformações afim (DeVries and Taylor 2017). Estas técnicas básicas irão permitir o foco não só globalmente, como também localmente nas imagens, dando ênfase a objetos que poderiam não ser detectados com as imagens originais, permitindo assim o modelo a aprender mais para obter maior generalização.

(DeVries and Taylor 2017) efetuou perturbações, interpolações e extrapolações nos exemplos por meio de codificadores e decodificadores para ampliar a quantidade de amostras de dados disponíveis para treinamento. Os codificadores aplicam transformações não lineares parametrizadas, convertendo-as em novas representações, normalmente menores do que as originais. Os decodificadores tentam efetuar a reconstrução das entradas originais, também por transformações não lineares. Diversas formas regularizadas de auto-encoders foram propostas, visando o aprendizado de novas representações.

No trabalho de (Acquarelli et al. 2017), *data augmentation* permitiu a criação de novas amostras de imagens para classificação espectro espacial de imagens hiper-espectrais de detecção remota. A técnica é baseada em *labels* e consiste em identificar vizinhos para pixels das imagens de treinamento originais, após isso é feita uma seleção de um subconjunto de pixels na vizinhança a partir de uma probabilidade p , a *label* de cada pixel de treinamento é transferida para os pixels vizinhos selecionados e após isso inserir os pixels selecionados com as *labels* inferidas nos dados de treinamento. Esta abordagem foi proposta para treinamento de uma rede neural de convolução.

Enfim, existem diversas maneiras de aumentar os dados da base de treino para obter

melhores resultados, a melhor forma vai depender muito das características do problema em questão. Nesta dissertação o uso de sobreposição dos dados foi aplicada e a descrição do método é explicitada na Seção 4.2.2.

2.5 Base de Dados Physionet

A Physionet (Goldberger et al. 2000) é uma popular base de dados que oferece acesso gratuito a diversas coleções de registros de sinais fisiológicos. É um serviço público do *PhysioNet Research Resource for Complex Physiologic Signals* e tem financiamento pelo *National Institute of General Medical Sciences* (NIGMS) e pelo *National Institute of Biomedical Imaging and Bioengineering* (NIBIB).

O *PhysioNet Resource* foi criado no ano de 1999 e tem como finalidade estimular investigações no estudo de sinais biomédicos e fisiológicos complexos tal como pesquisas atuais.

A *Physionet Resource* tem três componentes estreitamente independentes:

- **PhysioBank:** É um banco de dados que contém gravações digitais de sinais fisiológicos, séries temporais e dados voltados à comunidade biomédica. Inclui também várias coleções de dados de sinais cardiopulmonares, neurais e outros sinais biomédicos de pacientes saudáveis e com condições de saúde com implicações importantes para a saúde pública, com dados de morte súbita cardíaca, insuficiência cardíaca congestiva, epilepsia, distúrbios de marcha, apneia do sono e envelhecimento
- **PhysioToolkit:** É uma biblioteca crescente de software para processamento e análise de sinais fisiológicos e outras finalidades relacionadas a sinais biomédicos.
- **PhysioNetWorks:** Comunidade de colaboração para o laboratório virtual para trabalhar com pessoas do mundo todo em prol das publicações na *Physionet*.

Algumas bases de dados são voltadas para sinais de eletroencefalograma, e uma delas é muito popular para uso em testes de sistemas biométricos, é disponível publicamente¹. As gravações foram adquiridas de 109 sujeitos diferentes, utilizando 64 eletrodos posicionados na região do escalpo para armazenar os sinais (Conforme a Figura 2.4), cada

¹<http://physionet.org/pn4/eegmmidb/>

eletrodo é amostrado na frequência de 160 Hz. A base de dados foi criada pelos desenvolvedores do sistema de instrumentação BCI2000 e mantido pela Physionet. A Figura 2.3 mostra o sinal de EEG do eletrodo (*FC5*) nos primeiros 10 segundos de gravação, onde cada *grid* corresponde a 0,2 segundos

Na base de dados há 14 diferentes sessões de aquisições para cada indivíduo. Duas dessas 14 sessões contém 60 ou 61 segundos de duração, uma feita com o paciente em estado de repouso com os olhos abertos (EO) e outra com olhos fechados (EC). As 12 sessões restantes tem dados de 2 minutos de gravação cada, na qual os indivíduos realizam 4 diferentes tarefas motoras ou imaginárias (T1-T4) em 3 sessões ou *runs* (R1-R3), as atividades atribuídas as tarefas são:




Figura 2.3: Sinal de EEG do eletrodo FC5 amostrado em 10 segundos.




Figura 2.4: Posição dos eletrodos na região do escalpo. Fonte: <http://physionet.org/pn4/eegmmidb/>.

- Tarefa 1: Um alvo aparece no lado esquerdo ou direito da tela e o indivíduo abre e fecha o punho correspondente ao lado, até o alvo desaparecer. Após isso o indivíduo relaxa.
- Tarefa 2: Um alvo aparece no lado esquerdo ou direito da tela e o indivíduo imagina abrir e fechar o punho correspondente ao lado, até o alvo desaparecer. Após isso o indivíduo relaxa.
- Tarefa 3: Um alvo aparece na parte superior ou inferior da tela. O indivíduo abre e fecha ambos os punhos, caso o alvo esteja posicionado no topo e ambos os pés, caso esteja posicionado na parte inferior. Esta tarefa é executada até o alvo desaparecer. Após isso o indivíduo relaxa.
- Tarefa 4: Um alvo aparece na parte superior ou inferior da tela. O indivíduo imagina abrir e fechar ambos os punhos, caso o alvo esteja posicionado no topo e ambos os pés, caso esteja posicionado na parte inferior. Esta tarefa é executada até o alvo desaparecer. Após isso o indivíduo relaxa.

Capítulo 3

Revisão da Literatura

A biometria com sinais de EEG é um método muito promissor, por, teoricamente, ser menos suscetível a fraudes, que podem ser efetuadas em outras formas de biometria. Sinais de EEG são formados pelo fluxo da corrente iônica dos neurônios do cérebro. No cérebro há várias regiões e cada uma é ativada conforme a necessidade corporal. São normalmente explorados em aplicações médicas para diagnóstico de doenças vasculares cerebrais, epilepsias e outros distúrbios (Subasi and Ismail Gursoy 2010).

Usados na maioria dos estudos direcionados à biometria com EEG, as bases de dados contém sinais gravados de indivíduos em estado de repouso com olhos abertos (EO) ou com olhos fechados (EC) (Pozo-Banos et al. 2014). Por isso a Seção 3.1 aborda sobre trabalhos que utilizam estas bases de dados e a Seção 3.2 é sobre trabalhos direcionados a bases de dados com gravações de indivíduos realizando tarefas motoras ou imaginárias.

3.1 Estado de Repouso com EO e EC

Em 1980 a biometria com EEG foi introduzida por (Stassen 1980), em seu trabalho o objetivo era caracterizar uma pessoa por meio do padrão de espectro de EEG e classificar o espectro utilizando uma modificação de um método de reconhecimento de fala. A investigação se mostrou promissora, pois obteve 90% de probabilidade de confiança para análise de 82 sujeitos com idade entre 20 e 35 anos.

A extração características de EEG para identificação de pessoas usando o espectro de informações do sinal pelo FFT e classificação através de um algoritmos de geometria

computacional (interseções de polígono convexo) foi a proposta de (Poulos et al. 1999a). O autor procurou explorar o *Absolut Spectral Power* (ASP) do ritmo *alpha* (7-12.5 Hz). Uma base de dados própria denominada Poulos' DDBB que contém dados de 4 indivíduos, que incluem 45 seções gravadas. A acurácia do método para identificação reportada foi de 95%.

(Paranjape et al. 2001) fez uma análise sobre 349 segmentos de EEG a partir de 40 indivíduos, do qual aplicou modelos autorregressivos em várias ordens, fez uma análise discriminante e conseguiu 80% de acurácia na identificação de pessoas.

O uso de modelos autorregressivos (AR) para extração de parâmetros é também usado por (Mohammadi et al. 2006), para ser classificado por meio de uma rede neural de competição. Os autores propuseram dois métodos, o primeiro é baseado em canal único, que faz uso dos parâmetros AR como único vetor de características e obteve acurácia de 95% no melhor cenário, posteriormente utilizaram multicanais que efetua combinação dos parâmetros AR em diferentes canais para formar o vetor de características, obtendo precisão de 100% em diversos cenários.

(Palaniappan and Mandic 2007a) propôs uma análise sobre a capacidade de potências de frequência dominante nos sinais VEP (*Visual Evoked Potential*) aplicada à frequência *gamma* para realização de biometria, utilizando um conjunto de dados abrangentes e várias técnicas de classificação. As técnicas utilizadas compreendem *K-Nearest Neighbor* (KNN), classificadores da *Elman Neural Network* (ENN) e *10-fold Cross Validation*. A acurácia máxima foi obtida pelo ENN com média de 98.12 (desvio padrão).

O trabalho de (Tangkraingij et al. 2009) analisa quais os eletrodos de EEG que tem maior potencial para identificação biométrica, ou seja, os que são mais discriminantes. A gravação dos dados foi feita com os indivíduos em estado de repouso com olhos abertos e o algoritmo de análise de componentes independentes foi usado para separar dados de EEG derivados de vários canais e separá-los em fontes independentes. Após isso aplicaram rede neural para classificação. A classificação obteve 100% de acurácia para 20 indivíduos, usando todos os 16 eletrodos disponíveis e conseguiram manter o resultado usando apenas 3, apontando os mais discriminantes, são eles: Fp1, P3 e C4, que podem ser vistos na Figura 3.1.

(Singh et al. 2015) desenvolveu um trabalho com o objetivo de encontrar relações dos sinais gerados entre as regiões cerebrais para formar um padrão único que possa servir como característica discriminativa. Inicialmente é passado um filtro passa baixa para redução de ruído e então são feitos cálculos das relações dos sinais e utilizados como

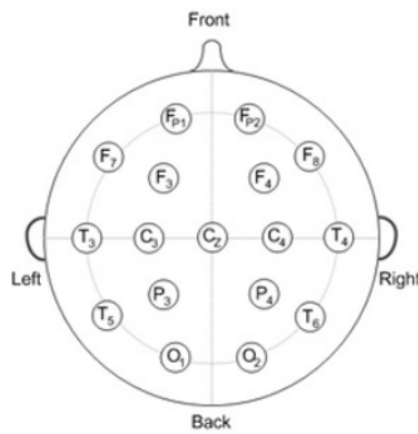


Figura 3.1: Eletrodos utilizados por (Tangkraingkiy et al. 2009).

Tabela 3.1: Quantidade de eletrodos utilizados e acurácia obtida. Extraída/Adaptada de (Singh et al. 2015).

Número de Canais	Acurácia (109 indivíduos)			
	64	10	6	5
Abordagem 1	100%	100%	97,24%	95,4%
Abordagem 2	100%	99,1%	91,7%	89%

características. E para abordar a variabilidade da amplitude de um sujeito para outro, foi utilizada uma medida bivariada, chamada *Magnitud Squared Coherence* (MSC), medida que depende da constância da fase enquanto uma área do cérebro interage com a outra. E por fim para classificação é utilizado o algoritmo KNN calculado pela distância euclidiana dos dados. Na seção de análise de resultados são executados testes para 64, 10, 6 e 5 canais. Após este processo feito para identificar os usuários, foram utilizadas duas abordagens, a primeira consiste em encontrar o ponto mais próximo de 5 amostras de cada indivíduo e então selecionar o valor mínimo final, (utilizando kNN com $k = 1$). E a segunda consiste em encontrar distâncias dos pontos de recurso de dados de teste a partir do valor médio calculado de cada ponto de característica de todas as 5 amostras de cada classe, em seguida é obtida a classe de distância mínima. Nos resultados deste artigo a abordagem 1 foi superior para todas as quantidades de canais, os resultados são expressos em EER e podem ser vistos na Tabela 3.1.

No trabalho de (Fraschini et al. 2015) foi utilizado o processo de verificação biométrica, na qual é proposta uma abordagem baseada na sincronização de fase. A base de dados

da *physionet* (Goldberger et al. 2000) é utilizada, com todos os 64 eletrodos. A metodologia utilizada pelo autor foi feita em quatro passos, no primeiro é realizada filtragem dos dados brutos para permitir fazer um estudo da frequência dos dados específicos das redes cerebrais. O segundo passo estima a interdependência estatística em pares entre séries temporais de EEG, após isso os dados são transformados em um grafo ponderado, no qual cada conexão funcional entre os eletrodos conectados na cabeça será uma aresta. E por fim, o quarto passo efetua a caracterização da organização funcional do cérebro, onde terá uma medida de centralidade para quantificar a importância de cada nó inserido na rede, esta medida é feita considerando a qualidade das conexões que são estabelecidas. Então, a classificação é feita utilizando um vetor com 64 elementos no qual tem-se expressadas a qualidade de cada nó da rede e em seguida são investigados as características únicas de cada indivíduo, para fazer definitivamente a biometria. Os resultados foram segmentados em frequências, visto que, quanto menor o tamanho da faixa de frequência nos dados fica mais difícil efetuar a identificação do indivíduo pelo EEG. As melhores acurácias foram obtidas pelos testes realizados na faixa de frequência *gamma* (30-50 Hz) onde obteve 4.4% de EER.

Algumas abordagens com redes neurais de convolução também foram propostas, (Ma et al. 2015) fez uso de CNN com 5 camadas, contendo duas camadas de convolução, duas de *pooling* e finalizando com uma *fully connected*. A avaliação é dada em cima da base de dados da *Physionet*, contudo, de 109 indivíduos somente 10 foram selecionados para teste. Dos 60 segundos disponíveis, 55 foram separados em fragmentos de 1 segundo para treinamento e os 5 restantes para teste amostrados a 160 Hz. Filtros passa-banda são empregados em diversas faixas de frequência. Os testes foram executados com dados dos indivíduos em estado de repouso com olhos abertos, olhos fechados e ambos. As taxas de classificação no cenário de identificação variaram de 64 a 86%.

3.2 Multitarefa

O primeiro estudo sobre atividade mental para biometria baseada em EEG foi em (Pallaniappan 2005). Neste trabalho foram extraídas características a partir de um modelo autorregressivo (AR) de sexta ordem. A base de dados utilizada contém dados de 9 indivíduos amostradas a 250 Hz e os sinais foram adquiridos durante 10 segundos para cada tarefa com 6 eletrodos. Quatro tarefas são realizadas durante as sessões de gravação: cálculos matemáticos, observar uma figura geométrica rodando, composição de cartas

para um amigo ou parente mentalmente e imaginar números sendo escritos e em seguida apagados em um quadro negro. A média de erro obtida foi de 0,95% para identificação de pessoas.

Um estudo sobre o efeito do tempo em um sistema de identificação baseado em EEG feito por (Marcel and Millan 2007) mostrou que quando dados de EEG adquiridos no mesmo dia são usados para treino e teste o desempenho piora, se comparado com o desempenho de dados captados em dias diferentes, em contrapartida, se dados de treinamento de sessões de vários dias forem usadas o problema pode ser contornado. A base de dados avaliada contém dados de 9 indivíduos em 12 sessões feitas em 3 dias, totalizando 4 por dia. Três tarefas são executadas pelos sujeitos: mover a mão para o lado direito, para o lado esquerdo, e imaginar palavras que iniciem com uma letra aleatória que aparece na tela, visto que as tarefas mudam a cada 15 segundos durante a gravação. As sessões realizadas no mesmo dia consistem em 4 minutos de duração com intervalo de 5 a 10 minutos entre uma e outra. A melhor performance obtida foi de 6,6% EER.

Em (Kostílek and Št'astný 2012), foi destacada a deterioração de resultados das tarefas mentais com o passar do tempo. A base de dados consiste em registros de 9 indivíduos e 53 eletrodos, duas sessões de aquisição de sinais foram feitas, com intervalo de um ano entre uma e outra. Nos experimentos executados com os sinais obtidos na primeira sessão parte para treino e o resto para teste, a taxa de classificação chegou a 98%. Contudo, para os testes da primeira sessão usados no treinamento e da segunda para testes, a acurácia foi de 87,1%

Em (Yang et al. 2016) foi usada a transformada *Wavelet* numa forma discreta, que tá sendo muito bem avaliada pela comunidade científica, uma vez que porque tem capacidade de capturar informação de sinais nos domínios de tempo e frequência. As frequência são divididas em níveis de classificação do qual dois são utilizados, o primeiro varia de 20 em 20 Hz no domínio de 0 a 80, e o segundo de de 10 em 10 Hz no mesmo domínio. Os dados EEG adquiridos de I eletrodos são segmentados em tempo em N janelas sobrepostas; Cada janela sobrepõe seu vizinho em 50%. Para uma dada janela de tempo, os dados de cada um dos eletrodos são transformados usando a transformada *wavelet packet decomposition* (WPD) multi-nível seguido por uma fase de realce de característica onde as derivadas dos coeficientes WPD são calculadas. Para cada uma destas faixas melhoradas, o desvio padrão (SD) é calculado. Os SD para todas as bandas e todos os eletrodos são então concatenados para produzir o vector de características para classificação utilizando um classificador LDA. As decisões do classificador de todas as janelas

de tempo são fundidas usando uma regra de votação majoritária. Os desempenhos deste sistema foram investigados para os cenários de identificação e verificação e a base de dados utilizada contém dados de pessoas executando as tarefas descritas na seção 2.5.

Três protocolos de testes foram adotados por (Yang et al. 2016), o primeiro protocolo investiga o impacto das regiões de eletrodos (lobo frontal, córtex motor e lobo occipital) e tipos de tarefas no desempenho do sistema. O segundo explora o uso de diferentes tarefas para treinamento e teste do sistema e consiste em usar dados de teste diferente dos dados de treino. Finalmente, o terceiro analisa a eficácia da combinação de dados de diferentes tarefas para treinamento com teste em apenas um tipo de tarefa e gravação (*run* T1R2). O resultado obtido foi 100% de acurácia no cenário de identificação e 2,63% EER no melhor cenário para verificação treinando nas tarefas T1+T2 e testando em T1R2, com uso de 9 eletrodos.

Uma abordagem de CNN é proposta por (Das et al. 2017) no qual os sinais passam por filtragem para redução de ruídos e na CNN são consideradas as seguintes camadas: uma de convolução, duas *max pooling*, uma de ativação, uma de perda e finalmente a *fully connected*. No protocolo de testes, foram adquiridos dados de 40 indivíduos, onde os mesmos são submetidos a estímulos visuais a partir de uma sequência de formas geométricas que são mostradas em um monitor. O círculo é considerado estímulo alvo e os observadores devem se concentrar nas ocorrências do alvo, ignorando o restante. Uma taxa de acurácia de 98,8% é encontrada para o esquema não-alvo contra não-alvo e 90.65% para alvo contra não-alvo.

Capítulo 4

Rede Neural de Convolução para Biometria Baseada em EEG

Neste capítulo será descrita a metodologia empregada para biometria baseada em EEG através de rede neural de convolução. A Seção 4.1 descreve o pré-processamento utilizado para filtrar os sinais e as bandas de frequência utilizadas. A Subseção 4.2.1 explica como é feita a divisão dos dados para treino, teste e validação e a Subseção 4.2.2 irá explicar como a técnica de *data augmentation* é utilizada. Por fim, a Seção 4.3 descreve a metodologia de obtenção da arquitetura e parâmetros para a rede neural de convolução.

4.1 Pré-Processamento

Os sinais de EEG obtidos da base de dados da *Physionet* são amostrados em 160Hz, porém utilizar toda essa faixa de frequência não é algo usual para biometria, pois algumas faixas de frequência são mais discriminantes que outras.

Para biometria baseada em sinais de EEG, normalmente são adotadas faixas de frequência abaixo da linha de 50 Hz (Yang and Deravi 2017). Algumas faixas são tipicamente consideradas para análise e estão amostradas na Tabela 4.1:

Um filtro passa banda FIR (Filtro de resposta a impulso finita) é responsável pelo processo de filtragem e foi utilizado para obter os sinais nas faixas de frequências desejadas, foram escolhidas 3 frequências de corte para realizar os experimentos. A primeira banda cobre das frequências delta até gamma (1-50Hz), a segunda está relacionada ao

Tabela 4.1: Faixa de frequências normalmente utilizadas em EEG.

Faixa de Frequência	Frequência
Delta	< 4 Hz
Theta	4-7 Hz
Alpha	8-12 Hz
Beta	12-35 Hz
Gamma	> 35 Hz

final da *alpha* até a *high beta* (10-30 Hz) e a terceira preserva o final da *beta* até a faixa *gamma* (30-50 Hz).

4.2 Processamento Dos Dados

4.2.1 Divisão dos Dados de Entrada

Os dados devem ser divididos em 3 conjuntos para realizar as fases de treinamento, validação e teste.

A etapa de treinamento para CNN consiste em apresentar os dados que vão ser responsáveis por ajustar o modelo, com o objetivo de emparelhar a entrada com o resultado esperado.

O conjunto de dados de validação ajuda a preparar o modelo, auxiliando na seleção de recursos e ajuste dos hiper-parâmetros, sua avaliação é mais tendenciosa, pois as características aprendidas no conjunto de dados de validação são incorporadas na configuração do modelo. Normalmente a curva de aprendizado no treino acompanha a curva de validação e com isso pode-se detectar *overfitting*.

Os dados de teste devem ser independentes dos dados de treinamento, porém segue a mesma distribuição de probabilidade que o conjunto de treino. O objetivo é treinar o modelo e generalizar o desempenho de um classificador, fazendo-o se encaixar bem no conjunto de dados de teste, ou seja o conjunto de dados de testes é um conjunto de amostras de exemplos para testar a eficácia do modelo.

A Figura 4.1 exemplifica como foram feitas as divisões no cenário de treino em EO




Figura 4.1: Exemplo de distribuição dos segmentos de EEG usados para treino em EO e teste em EC.

e teste em EC. Os dados são divididos em segmentos de 12 segundos, buscando seguir a proposta de (Fraschini et al. 2015) e seu protocolo de avaliação. Dos dados da fase de treinamento, 90% foram separados para treino e 10% para validação durante 60 épocas, com o uso de sobreposição dos dados (*data augmentation*), que será explicado na Seção 4.2.2. Para os dados de teste não é utilizada a sobreposição, portanto as amostras de entrada contém o seu tamanho total dividido pelo tamanho dos segmentos (12 segundos). No caso da Figura 4.1, está exemplificando os dados *baseline* da base de dados *physionet*, com EO e EC, cada amostra de um indivíduo contém 60 segundos e para teste pode-se verificar 5 segmentos de 12 segundos (1920 amostras) cada, no caso de tarefas essa quantidade dobra pois o dobro do tempo de gravação está disponível na base de dados.

4.2.2 Data Augmentation

Seguindo o protocolo de avaliação proposto por (Fraschini et al. 2015), os dados de EEG foram divididos em segmentos de 12 segundos cada (1920 amostras), portanto, ao dividir os 60 segundos de EO e EC, resultaria em 5 segmentos por indivíduo e para tarefas (T1-T4) 10 segmentos. No entanto, 5 ou 10 segmentos por indivíduo não são suficientes para treinamento de uma rede neural de convolução.

Para aumentar a quantidade de dados disponíveis e ajudar a evitar *overfitting* no modelo, é proposta a técnica de *data augmentation*. A estratégia é bem simples e consiste em sobrepor abundantemente os dados entre os segmentos de EEG, criando novos segmentos à partir do sinal filtrado com o uso de uma janela deslizante. Normalmente na

técnica de *data augmentation* em imagens os dados são modificados para acrescentar variabilidade no modelo, porém nos sinais de EEG isso pode gerar perda de características, por esse motivo a sobreposição dos dados foi proposta, mantendo o sinal original mas multiplicando sua quantidade nas instâncias de treino.

Os novos segmentos são criados utilizando o sinal todo do indivíduo e a partir da amostra no tempo 0 irá extrair o primeiro segmento, correspondendo ao tempo (dos sinais de gravação) 0-12 segundos, então há um incremento de 20 amostras ou 0,125 segundos, gerando um novo segmento correspondente ao tempo 0,125-12,125 segundos. Isso é feito como se fosse uma janela deslizante de 20 em 20 segmentos, esse procedimento é realizado até chegar no final da gravação do sinal. Esta técnica permitiu produzir 42696 novas instâncias de treinamento para EO e 95801 para tarefas.

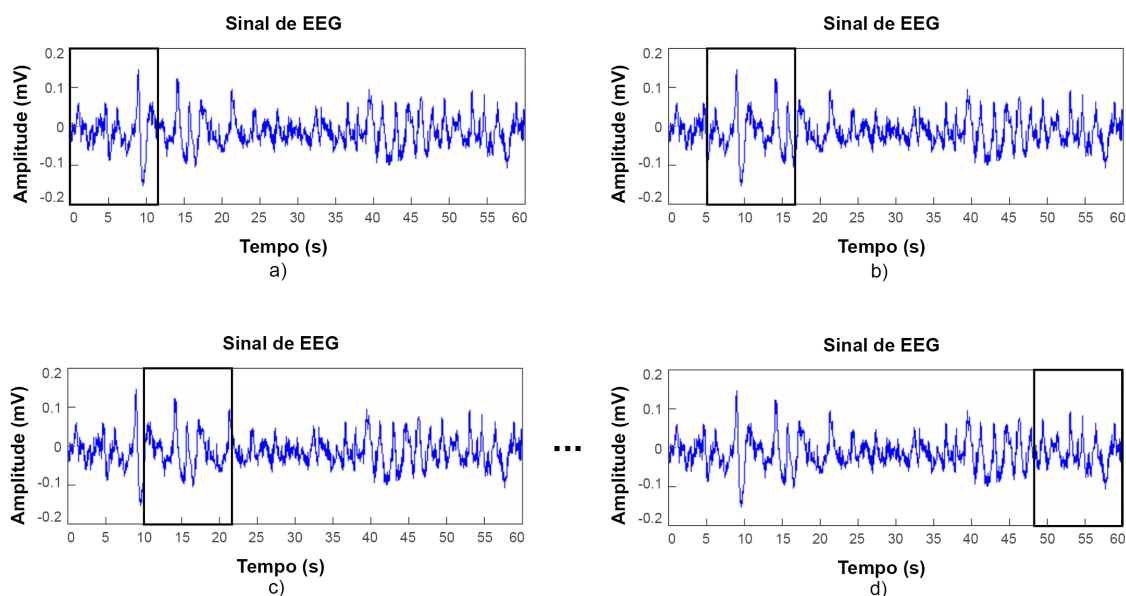


Figura 4.2: *Data augmentation* com janela deslizante de tamanho 12 segundos. Temos em a) janela na posição *offset* 0, primeiro segmento criado. b) *offset* de 5 segundos. c) *offset* de 10 segundos e d) último segmento criado, após a janela deslizar sobre todo o sinal.

A Figura 4.2 mostra um exemplo de *data augmentation*, com janela deslizante de tamanho 12 segundos e deslocamento de 5 segundos. Estes valores foram usados para efeitos de visualização da imagem.

4.3 Rede Neural de Convolução

Assim como citado na Subseção 2.3.1, uma rede neural de convolução necessita de uma arquitetura, e sua estrutura típica é composta de uma série de operações empilhadas que inicia com camadas de convolução, seguido por ativação, no caso do presente trabalho com ReLU, *pooling*, normalização e enfim, camadas *fully connected* (LeCun et al. 2015).

Na Figura 4.3 pode-se ter uma noção melhor do funcionamento do modelo adotado. A entrada tem tamanho $1920 \times 1 \times 64$, e os filtros são unidimensionais, proporcionalmente adaptados para o sinal de EEG. O valor 1920 corresponde a um segmento de 12 segundos, o valor 1 significa que o sinal é uni-dimensional e finalmente, 64, corresponde a quantidade de eletrodos disponíveis.

Na fase de treinamento, o sinal de entrada é lançado pelas camadas da rede. Cada camada representa uma ou mais operações da CNN: convolução; pooling; stride; ativação (ReLU); normalização (L2 Norm). A rede é composta por 3 convoluções seguidas de *pooling*, e por fim, 4 camadas *fully connected*, seguida da camada de perda *softmax-loss* e *dropout*. Esta configuração foi definida empiricamente com base nos erros obtidos no processo de validação.

Para o treinamento da rede neural de convolução, o uso de três arquiteturas de CNN foram investigadas. A primeira com pequenos campos receptivos na primeira camada de convolução, essa ideia foi inspirada no trabalho de (Simonyan and Zisserman 2014). As outras duas contêm campos receptivos maiores, inspirados por (Krizhevsky et al. 2012, Zeiler and Fergus 2014).

Para a tarefa de verificação, necessitamos de um vetor de características, com a finalidade de realizar a biometria, por isso após a fase de treino, as últimas três camadas da rede são removidas, a camada de custo *softmax*, *dropout* e a *fully connected 4* (FC4). A nova saída da rede é usada como o vetor de características para um segmento de 12 segundos de EEG. Após esse processo, são criados pares intra-class (genuínos) e inter-class (impostores) pelo processo de verificação, para serem classificados por meio de distância euclideana, que calcula a similaridade entre dois vetores de características.

A função de ativação ReLU (Ativação linear retificada) é utilizada nas camadas de convolução, é expressa pela Equação 4.1 e sua derivada pela Equação 4.2. ReLU é menos cara computacionalmente do que outras funções de ativação, tais como a *sigmoid* e *tanh* por envolver cálculos mais simples.

$$\text{ReLU}(x) = \max\{0, x\} \quad (4.1)$$

$$\text{ReLU}'(x) = \begin{cases} 1 & \text{Se } x \geq 0. \\ 0 & \text{Caso contrário.} \end{cases} \quad (4.2)$$

A biblioteca *MatConvNet* (Vedaldi and Lenc 2015) foi utilizada para a criação e treinamento da CNN, esta biblioteca foi criada para ser utilizada no MATLAB, sua implementação é *open source* e é voltada para aplicações de visão computacional.




Figura 4.3: Modelo *deep learning*.

Capítulo 5

Experimentos e Discussões

Neste capítulo é apresentada a avaliação do método proposto para biometria baseada em sinais do eletroencefalograma. A avaliação é realizada seguindo o protocolo proposto por (Fraschini et al. 2015) para testes em EO e EC, nos testes multitarefas foi escolhida uma tarefa para testes e o restante para treinamento. Características da base de dados são lembradas na Seção 5.1. Detalhes do modelo e parâmetros utilizados para compôr os experimentos são amostrados na Seção 5.2. Os resultados encontrados e discussões estão expressos na Subseção 5.2.1. Os resultados são apresentados em termos de curvas DET e EER.

5.1 Características da Base de Dados

No presente trabalho a base de dados *Physionet* (Goldberger et al. 2000) foi utilizada para treinamento e avaliação do método proposto. A base foi melhor detalhada na Seção 2.5, porém com o intuito de facilitar a leitura do documento, é novamente apresentada aqui.

O banco de dados é amplamente utilizado em estudos de doenças, biometria e qualquer aplicação voltada para o estudo dos sinais de EEG e contém amostras de 109 indivíduos diferentes, com 64 eletrodos posicionados na região do escalpo para armazenar os dados, todos amostrados à frequência de 160 Hz.

O banco de dados foi criado pelos desenvolvedores da BCI2000 *instrumentation system* e é mantido pela *Physionet*. Há 14 aquisições diferentes para cada sujeito, cada uma

está relacionada a uma diferente tarefa, seja ela motora ou imaginaria, onde o indivíduo recebe a instrução para executá-la durante a gravação. Considerando essas 14 sessões, há duas sessões base que contém 60 ou 61 segundos cada, nas duas o sujeito está em estado de repouso, uma com os olhos abertos (EO) e outra com os olhos fechados (EC). O restante das sessões estão relacionadas a 4 tipos de tarefas (T1-T4), em 3 sessões de captação de sinais (R1-R3) e as amostras contém dois minutos de gravação. Na primeira e terceira tarefa são executadas ações imaginárias e na segunda e quarta ações motoras.

Todas as amostras foram utilizadas no processo de treino e teste, conforme os protocolos aqui propostos. A ideia principal foi fazer o treino e teste em tarefas distintas, para mostrar que independente das amostras utilizadas para treino e teste, a biometria com os sinais de EEG é eficaz.

5.2 Experimentos

Os experimentos foram conduzidos em um Intel (R) Core i7-5820K CPU @ 3.30GHz 12-núcleos, 64GB de RAM DDR4 e uma GeForce GTX TITAN X GPU.

A implementação do método foi feita em Matlab e a biblioteca escolhida para executar a CNN foi o MatConvNet (Vedaldi and Lenc 2015) conectado a NVIDIA CuDNN.

A realização dos experimentos neste trabalho, foi separada em duas partes. Inicialmente foram executados testes referentes às amostras *baseline* (EO-EC), buscando investigar a faixa de frequência mais discriminante. A segunda parte dos experimentos foram executados utilizando a melhor banda de frequência dos testes *baseline* para algumas tarefas e testar seu funcionamento em ambientes menos controlados.

Durante a fase de treino, 90% dos dados são separados pra treinamento e 10% para validação, assim como foi explicado na Seção 4.2.1. O *data augmentation* é usado nos dados de treino e para a seção de EO, permitiu criar 384 ou 392 (de 60 ou 61 segundos disponíveis) segmentos de 1920 amostras (12 segundos) por indivíduo. Para as sessões envolvendo tarefas (T1-T4), são criados 889 ou 905 (123 ou 125 segundos) segmentos para cada indivíduo.

Para desenvolvimento da arquitetura apresentada na Tabela 5.1, a largura e a profundidade das redes foram ajustadas empiricamente conforme a evolução dos resultados, baseados nos erros de validação durante a fase de treino.

As camadas de *pooling* executam a operação de *max-pooling*, e a última camada é a camada de perda *soft-max loss one*. As camadas FC com tamanho de filtro 1×1 (FC2, FC3 e FC4) são usadas para redução de dimensão e ativação linear retificada (*Rectified Linear Activation*).

Tabela 5.1: Arquitetura proposta para biometria com EEG.

Nome	Tipo	Entrada Tamanho	Número de Filtros	Tamanho do Filtro /Stride/Pad	Relu	Norm
Arquitetura						
Conv1	conv	1x1920	96	1x11/1/0	sim	sim
Pool1	max pooling	1x1910	N/A	1x2/4/0	não	não
Conv2	conv	1x478	128	1x9/1/0	sim	sim
Pool2	max pooling	1x470	N/A	1x2/2/0	não	não
Conv3	conv	1x235	256	1x9/1/0	sim	sim
Pool3	max pooling	1x227	N/A	1x2/2/0	não	não
FC1	full. conn.	1x113	4096	1x113/1/0	sim	não
FC2	full. conn.	1x1	4096	1x1/1/0	sim	não
FC3	full. conn.	1x1	256	1x1/1/0	não	sim
FC4	full. conn.	1x1	109	1x1/1/0	não	não
Drop	Dropout	1x1	2	N/A	não	não
Custo	Softmax	N/A	N/A	N/A	N/A	N/A

Na CNN três *learning rates* (LRs) são distribuídos durante 60 épocas, a distribuição pode ser vista na Tabela 5.2. Essa distribuição de LRs foi obtida pela observação do erro de validação, quando o erro estagnava, o LR era dividido por 10. Os *mini batches* tem tamanho 100 para demandar menos recursos de memória e coeficiente de momento em 0.9 (para acelerar a descida do gradiente) são considerados durante todo o treino. O peso dos filtros é inicializado aleatoriamente e o algoritmo *stochastic gradient descent* (SGD) é usado para otimização. A operação de *dropout* é posicionada após a última camada, em 10% para melhora na validação.

Tabela 5.2: Distribuição dos *learning rates* durante as épocas de treino.

LR	Épocas
0.01	2
0.001	35
0.0001	23

No processo de verificação biométrica, o presente protocolo produziu 1086 pares genuínos (intra-classes) e 146610 pares impostores (inter-classes) para os registros *baseline* (Treino EO- Teste EC) e 4809 pares intra-classes e 571.392 pares inter-classes para tarefas (Treino T1R1 - Teste T1R2, por exemplo).

Os testes são realizados em EC, quando o treino é feito em EO, e T1R2, quando envolvem tarefas. O uso de sobreposição dos dados (*data augmentation*) é descartado, pois somente na fase de treino é necessária grande quantidade de dados, visando a generalização e melhor aprendizado do modelo e também para manter compatibilidade com o protocolo de (Fraschini et al. 2015) para avaliação, com mesma quantidade de pares intra-classes e inter-classes na tarefa de verificação. Para teste 5 segmentos são extraídos de EC e 10 segmentos de T1R2.

5.2.1 Discussão de Resultados

A Tabela 5.3 mostra o EER obtido para cada faixa de frequência testada, na banda que compreende 01-50 Hz, o EER obtido é de 11.2%, obtendo o pior resultado relativo aos testes de frequência. Na faixa referente a 10-30 Hz o EER obteve uma melhora considerável, com 6.25%. A faixa *gamma*, de 30-50 Hz se destacou, pois conseguiu 0.19% de EER, a performance foi absolutamente maior que o restante dos testes.

A Figura 5.1 mostra o desempenho dos experimentos realizados por meio da curva DET, a curva expressa a relação entre FAR, FRR e EER por meio de variação de limiar. A curva relacionada a frequência de 30-50 Hz superou todos os outros experimentos e também resultados publicados na literatura. Como mostrado por (Fraschini et al. 2015), a melhor faixa de frequência para biometria baseada em EEG é a faixa *gamma*, embora a discrepância de resultados com as outras faixas de frequência são maiores aqui.

Tabela 5.3: EER obtido de faixas de frequências específicas.

Faixa de Frequência	de EER
01-50 Hz	11.2%
10-30 Hz	6.25%
30-50 Hz	0.19%




Figura 5.1: Curva DET para os experimentos propostos testando as faixas de frequência.

Na Tabela 5.4 encontra-se uma comparação com o trabalho de (Fraschini et al. 2015), considerado estado-da-arte na biometria de EEG. E como pode-se perceber o método proposto com o uso de redes neurais de convolução reduziu de forma significativa o EER. O protocolo de testes utilizado é o mesmo, por isso os efeitos comparativos tornam-se válidos para os métodos.

A sequência de testes é dada com a faixa de frequência *gamma* para as tarefas 1 a 4 (T1-T4), por motivos de ser a mais discriminante no âmbito de biometria baseada em EEG.

Em (Yang et al. 2016), foi proposta uma mistura de dados de treinamento e teste

Tabela 5.4: Comparação com trabalhos relacionados.

Trabalhos	Abordagem	Treino-Teste	Eletrodos	Indivíduos	EER(%)
(Fraschini et al. 2015)	Eigenvector Centrality	EO-EC	64	109	4.40
Método Proposto	CNN	EO-EC	64	109	0.19

para T1-T4, incluindo treino com uma ou mais tarefas com teste em T1R2, treino nas 4 tarefas individualmente usando a R1 e R3 delas e testando em todas as tarefas em R2. No entanto, nesta dissertação o treinamento é realizado com todos os registros de tarefas disponíveis na base de dados, com exceção de T1R2, que foi escolhida para teste, sem acúmulo de tarefas nos dados de treino.

Os resultados dos testes multitarefas podem ser vistos na Tabela 5.5. A arquitetura não generalizou para todas as tarefas propostas, porém para T2R1-T1R2 e T1R1-T1R2 obteve resultados bons, em um deles inclusive, superou o melhor dos testes *baseline* (EO-EC) feitos nesta dissertação. A mesma arquitetura foi utilizada nos dois cenários, no entanto, nos testes *baseline* o aprendizado é facilitado, pois há evidências que em estado de repouso, as atividades elétricas se organizam e coordenam as funções neuronais (Ma et al. 2015), trabalhando de uma forma mais sistematizada, esta mesma arquitetura não funcionou bem para tarefas, apesar de ter obtido EER de 0,08%, no caso de T1R1-T1R2 e 0,2% para T2R1-T1R2.

Tabela 5.5: Resultados expressos em termos de EER com o uso de tarefas.

Treino	Teste	EER(%)
T1R1	T1R2	0.0853
T1R3	T1R2	50.4
T2R1	T1R2	0.20
T2R2	T1R2	50
T2R3	T1R2	50,01
T3R1	T1R2	49,99
T3R2	T1R2	50
T3R3	T1R2	32,41
T4R3	T1R2	50

A Figura 5.2 representa o desempenho dos dois melhores resultados obtidos expressos pela curva DET. As curvas referentes aos outros resultados obtidos não foram feitas por não terem desempenho comparável, inseri-las geraria uma discrepância enorme, impossibilitando a visualização das curvas referentes a T1R1-T1R2 e T2R1-T1R2.




Figura 5.2: Curvas DET dos resultados satisfatórios obtidos com o uso de tarefas.

Na Tabela 5.6 encontra-se uma comparação com o trabalho de (Yang et al. 2016), que fez testes com uma mistura nos dados de treino e testes nas tarefas, o autor conseguiu no melhor caso 2,63% EER treinando em T1+T2 e testando em T1R2. O método proposto nessa dissertação parece ser promissor, pois os resultados encontrados que estão demonstrados na tabela reduziram muito o EER, e a utilização de 64 eletrodos também mostra a robustez do método, visto que nem todos os eletrodos contribuem para a identificação de indivíduos (Yang et al. 2016), alguns podem se comportar somente como sinais ruidosos e prejudicar a eficácia do método. Novos experimentos são desejáveis com uma menor quantidade de eletrodos mais biometricamente relevantes para verificar se pode haver melhora nos resultados. O presente trabalho deixa a desejar na generalização.

Três trabalhos foram encontrados na literatura que usam CNN para biometria baseada em EEG (Das et al. 2017, Ma et al. 2015, Mao et al. 2017), todos eles usam o

modo de identificação, cada um com uma base de dados diferente. O único que propôs testes na base da *Physionet* foi (Ma et al. 2015), todavia, os autores usaram somente dados de 10 indivíduos, facilitando as chances de acertos, pois quanto menor a quantidade de indivíduos, menores são as chances de erro, tornando assim o protocolo mais fraco. Nenhum dos trabalhos utilizou do artifício de *data augmentation* para gerar maior quantidade de dados para treinamento.

Tabela 5.6: Comparação com trabalhos relacionados multitarefas.

Trabalhos	Abordagem	Treino-Teste	Eletrodos	Indivíduos	EER(%)
(Yang et al. 2016)	Wavelet Coefficients	T1+T2-T1R2	9	108	2.63
Método Proposto	CNN	T3R3-T1R2	64	109	32.4
Método Proposto	CNN	T2R1-T1R2	64	109	0.2
Método Proposto	CNN	T1R1-T1R2	64	109	0.08

Os melhores resultados encontrados nas tarefas (vide Tabela 5.5) mostram que o uso de CNN para biometria com EEG é possível e se for encontrada uma arquitetura capaz de fazer uma generalização mais efetiva este será um caminho promissor.

O desempenho obtido no cenário multitarefas pode estar associado ao emprego da faixa *gamma* no protocolo de testes, pois cada faixa está associada a uma atividade cerebral (Boubakeur et al. 2017) e isto pode estar impedindo o método de convergir para resultados com maior generalização. Novos testes devem ser feitos, explorando mais a questão do *data augmentation*, visto que, a quantidade de amostras disponíveis para treino dobra quando usadas tarefas e propondo novas arquiteturas. Inserir novas tarefas no conjunto de testes também é desejável, para ver até onde esse fenômeno de não generalização se estende.

Capítulo 6

Conclusões e Trabalhos Futuros

Esta dissertação apresenta uma proposta para representação de sinais do eletroencefalograma (EEG) baseada em *deep learning*, com uso de Redes Neurais de Convolução (CNN). O método foi avaliado na base de dados *Physionet*, que contém dados de 109 indivíduos amostrados a 160 Hz e em 14 sessões de gravação. O modo biométrico de verificação é empregado para avaliar o desempenho do modelo.

A contribuição do presente trabalho é a arquitetura e a técnica de *data augmentation*. A técnica de *data augmentation* aqui empregada visa produzir maior quantidade de dados disponíveis para treinamento da rede neural. Para treinar uma CNN é necessária grande quantidade de dados e a sobreposição dos segmentos de EEG foi fundamental para os resultados alcançados.

Em particular, nossa proposta obteve excelentes resultados em ambos cenários de teste. Nos experimentos *baseline*, com treino nos segmentos de EEG de indivíduos em estado de repouso com olhos abertos (EO) e teste nos segmentos referentes a olhos fechados (EC) foi feita análise sobre três faixas de frequência empregadas (01-50 Hz, 10-30 Hz, 30-50 Hz) nos sinais. Mostrou-se que a faixa que agrega mais valor e torna as características de EEG mais discriminantes nesse cenário foi a faixa *gamma* (30-50 Hz), onde foram obtidos resultados que superaram resultados publicados na literatura, como o trabalho de (Fraschini et al. 2015). Reduzindo o EER de 4,5% para 0,19%.

Novos testes foram propostos para as tarefas (T1-T4), efetuando o treinamento em sessões de todas as tarefas com exceção de T1R2, usada para teste. A faixa de frequência empregada foi a mesma dos testes iniciais (30-50 Hz), por parecer ser mais valiosa, de um ponto de vista biométrico. O modelo obteve resultados muito bons com treino em T2R1

e T1R1, com 0,2% e 0,08% de EER, respectivamente, mostrando que resultados próximos da otimalidade podem ser alcançados. O único problema foi a não generalização para o restante dos testes.

Novas investigações devem ser realizadas, com o propósito de promover uma generalização maior com testes multitarefas. Podem ser exploradas: a proposta de novas arquiteturas, exploração de outras faixas de frequência e apuração no uso de *data augmentation* com novas técnicas e diferentes sobreposições de sinais.

A redução na quantidade de eletrodos também é desejável, para a CNN lidar somente com os mais discriminantes, apesar do método mostrar robustez pelo uso dos 64 eletrodos disponíveis, visto que, nem todos os eletrodos contribuem para a identificação e podem prejudicar o aprendizado.

A CNN é muito utilizada em aplicações de visão computacional e se mostrou uma forte técnica para representação do sinal de EEG para biometria, obtendo resultados superiores aos publicados na literatura. Ainda há muito a ser analisado para treinamento da rede, pois apesar da robustez e eficácia do método podemos melhorá-lo ainda mais explorando seu poder de aprendizado.

O sistema biométrico baseado em EEG pode ser promissor no futuro por ser difícil de ser clonado e, como os sinais mudam conforme o pensamento/tarefa que está sendo executada pelo indivíduo, fornece mais integridade e autenticidade nesta modalidade biométrica. Com os grandes avanços tecnológicos nos aparelhos de captação de sinais de EEG, pode-se promover uma difusão nessa modalidade futuramente, pois esta ainda lida com problemas como bases de dados com pouca quantidade de indivíduos.

Apêndice A

Apêndices

A.1 Publicações

Convolutional Network for EEG-Based Biometric

Thiago Schons¹, Gladston. J. P. Moreira¹, Pedro H. L. Silva¹, Vitor N. Coelho²
and Eduardo. J. S. Luz¹

¹ Computing Department, Universidade Federal de Ouro Preto,
Ouro Preto, Minas Gerais, Brazil.

² Department of Computer Science, Universidade Federal Fluminense,
Niteroi, Rio de Janeiro, Brazil.

Abstract. The global expansion of biometric systems promotes the emergence of new and more robust biometric modalities. In that context, electroencephalogram (EEG) based biometric interest has been growing in recent years. In this study, a novel approach for EEG representation, based on deep learning, is proposed. The method was evaluated on a database containing 109 subjects, and all 64 EEG channels were used as input to a Deep Convolution Neural Network. Data augmentation techniques are explored to train the deep network and results showed that the method is a promising path to represent brain signals, overcoming baseline methods published in the literature.

1 Introduction

Humankind has urged for safety in all spheres of our society, thus, as technology evolves in this direction, also evolves efforts to overcome security systems. In this context, current biometric systems are in constant development, and new forms of capture discriminant and robust traits among people are desirable. The present work deals with the use of electroencephalogram (EEG) signals for *biometry task*, since the EEG is difficult to fake or steal.

The seminal work presented in [8] showed the feasibility of using the EEG to biometric task, and since that, many approaches using EEG have been proposed such as in [2] where authors performed biometric verification on Physionet EEG database. Authors concluded that the best frequency band for EEG biometric is the gamma band (30-50 Hz), where they reported 4.4% of equal error rate (EER). Their approach is based on phase synchronization, in which the Eigenvector Centrality obtained from every node (subject) is the feature vector. Signals on resting condition are considered for the analyses in two scenarios.: eyes open and eyes closed.

In [12], four different task conditions, related to signal motor movement and imagery tasks are investigated. A novel wavelet-based feature was used to extract EEG feature. Experiments were conducted in Physionet EEG data and a mixture of data, from different sessions, is used for training. Only nine electrodes are considered and the lowest EER achieved is 4.5%.

Several machine learning and pattern recognition techniques were investigated aiming to identify a person by means of EEG signals, however, to the best of our knowledge, deep learning based methods as Convolutional Neural Networks (CNN) [7] have not been evaluated yet. Deep learning has been used to represent patterns in several computer vision and patterns recognition problems, and outstanding results have been reported [1, 5].

In this work, a novel approach for EEG representation based on deep learning is proposed. The approach is also evaluated on the Physionet database, and data augmentation techniques are explored to train a deep convolutional neural network. Results show that the use of CNN in EEG biometrics is a promising path, outperforming baseline methods by lowering the EER from 4.4% to 0.19% in the best scenario.

The remainder of this paper is organized as follows. Section 2 contains the approach with the methodology and a description of the database used. In Section 3, we show the experimental results and a discussion about it. Finally, in Section 4, the conclusions are presented.

2 Approach

In this section, the Physionet EEG database is described as the proposed method, based on the convolutional network, along with the required pre-processing steps.

2.1 Physionet EEG Database

The Physionet EEG Database [3] is a popular benchmark in the literature for biometric with EEG and it is public available³. The records were acquired from 109 different subjects, using 64 electrodes in the region of the scalp to store the EEG signals (see Figure 1), each sampled at 160 Hz. The database was created by the developers of the BCI2000 instrumentation system⁴ and maintained by Physionet. There are 14 different acquisition sessions for each subject, each one with different motor/imagery tasks considered during recording. Among those 14 sessions, there are two one-minute (60 or 61 seconds per record) baseline runs (one with eyes open (EO), one with eyes closed (EC)). The others sessions are related to four kinds of tasks of three two-minute runs.

2.2 Methodology

Data pre-processing: To further investigate the feasibility of the method, only resting state EEG data is considered. Thus, the baseline sessions - data captured where the subject is with EO and EC - are used during experiments.

All EEG recording signals are band-pass filtered in 3 frequency bands. The first band covering from delta to gamma frequencies (1-50 Hz), the second band

³ <http://physionet.org/pn4/eegmddb/>

⁴ <http://www.bci2000.org>

After the learning process, last three layers are removed (Softmax, Dropout, and FC4 as seen in Table 1) and the new network output is used as a feature vector for a 12 seconds EEG segment, which will be used for verification task.

In verification task, the performance of methods is expressed in terms of Detection Error Trade-off (DET) curves, which show the trade-off between type I error (false acceptance error - FAR) and type II error (false rejection error - FRR). To construct the DET curve, all instances from testing dataset are compared to each other, in an all-against-all scheme. Verification task can be modeled as the Equation 1, where S is the function that measures the similarity between two feature vectors (X_1 and X_2) and t is a predefined threshold [4]. The value $S(X_1, X_2)$ is the similarity or matching score between the biometric measurements with Euclidean distance. A person's identity is claimed and classified into genuine when pairs are similar and impostor, otherwise. After that genuine (intra-class) and impostor (inter-class) distribution curves are generated from similarities scores.

$$(X_1, X_2) \in \begin{cases} \text{genuine}, & \text{if } S(X_1, X_2) \geq t \\ \text{impostor}, & \text{otherwise} \end{cases} \quad (1)$$

3 Experimental Results and Discussion

Experiments were conducted on an Intel (R) Core i7-5820K CPU @ 3.30GHz 12-core machine, 64GB of DDR4 RAM and one GeForce GTX TITAN X GPU. The MatConvNet library is used for the convolutional networks [11] linked to NVIDIA CuDNN.

Data segmentation for experiments was performed following the evaluation proposed in [2], where the window size consists of 12 seconds (as detailed in Section 2.2).

Data augmentation is used on data from EO session (training data), yielding 384 or 392 (from 60 and 61 seconds) segments of size 1920 samples (12 seconds)




Fig. 2: Deep learning model.

Table 1: Architecture for EEG biometry.

Name	Type	Input Size	Number of Filters	Filter Size /Stride/Pad	Relu	Norm
Network Arch						
Conv1	conv	1x1920	96	1x11/1/0	yes	yes
Pool1	max pooling	1x1910	N/A	1x2/4/0	no	no
Conv2	conv	1x478	128	1x9/1/0	yes	yes
Pool2	max pooling	1x470	N/A	1x2/2/0	no	no
Conv3	conv	1x235	256	1x9/1/0	yes	yes
Pool3	max pooling	1x227	N/A	1x2/2/0	no	no
FC1	full. conn.	1x113	4096	1x113/1/0	yes	no
FC2	full. conn.	1x1	4096	1x1/1/0	yes	no
FC3	full. conn.	1x1	256	1x1/1/0	no	yes
FC4	full. conn.	1x1	109	1x1/1/0	no	no
Drop	Dropout	1x1	2	N/A	no	no
Cost	Softmax	N/A	N/A	N/A	N/A	N/A

per subject. For evaluation, five segments of 12 seconds are extracted for each subject from EC session, i.e., no overlapping during the test (See Figure 3).

During training, the input signal, represented by a 12 seconds length EEG time series, is feed-forwarded through network layers. Each layer represents one or more CNN operations: convolutional filter; pooling; stride; rectification (RELU); normalization (L2 Norm). Convolutional stride and padding are set to one. Pooling layer performs a max-pooling operation, and when there is down-sampling ($stride > 1$), it happens in conjunction with pooling. The stack of layers are followed by *Fully-Connected* (FC) layers and the last FC layer is for classification. These FC layers can be seen as multi-layer-perceptron (MLP) network.

The final layer is a soft-max loss one. The FC layer with 1×1 filter size is used for dimension reduction and rectified linear activation. The network architecture is presented in Table 1.

For training the network, three learning rates of value $L = [0.01, 0.001, 0.0001]$ are distributed over the epochs, mini batches are set to size 100, and a momentum coefficient of 0.9 is considered during all training. Filter weights are randomly initialized and stochastic gradient descent is used for optimization. The dropout operation is placed before the last layer with 10% to minimize overfitting.

During the training phase, 90% of the data is reserved for training and 10% for validation as shown in Figure 3. The CNN are trained for over 60 epochs.

Evaluation is carried in verification mode and the metric used to report results is *Equal Error Rate* (EER) which, in turn, is defined as the point where the




Fig. 3: The distribution of ECG segments used for training and testing.

False Acceptance Rate (FAR) is equal to the *False Rejection Rate* (FRR). FAR and FRR are generated from intra-class and inter-class pairs comparison. The present protocol produces 1086 genuine (intra-class) pairs and 146610 impostors (inter-class) pairs. In Figure 4, DET curve shows the relationship between FAR, FRR, EER by means of a threshold variation.

Table 2: EER obtained for the specified frequency bands.

Frequency band	EER
01-50 Hz	11.2%
10-30 Hz	6.25%
30-50 Hz	0.19%

The DET curves in Figure 4 depicts the performance for the detailed experiments. The curve related to 30-50 Hz resulted in an overall performance of 0.19% EER as shown in Table 2, overcoming results published in the literature. As shown in Fraschini et. al. [2], the best frequency band for EEG biometrics is the gamma band. The results presented here confirm the findings in [2] regarding frequency band, however, the discrepancy of results with other frequency bands was greater here. More experiments are needed to investigate whether this phenomenon extends to other tasks (T1-T4) or even other databases.

Results presented in Table 3 compares the proposed method with state-of-the-art approaches. As can be noticed, the proposed method significantly reduced the EER. The usage of all 64 EEG channels shows the robustness of the method since it was able to handle all electrodes, even if not all of them effectively contribute to the identification of individuals [12].

4 Conclusions

In this work, the use of CNN in an EEG-based biometric system is investigated for the first time. When compared to the baseline methods presented in the




Fig. 4: DET Curve for proposed experiments.

Table 3: Comparison with related works.

Reports	Features	Train-Test	Electrodes	Subjects	EER(%)
Fraschini et. al. [2]	Eigenvector Centrality	EO-EC	64	109	4.40
Yang et. al. [12]	Wavelet Coefficients	T1-T4	9	108	4.50
Proposed work	CNN	EO-EC	64	109	0.19

literature (under the Physionet EEG database), EEG data represented by the CNN model showed a lower EER for person recognition (verification mode).

The contribution of this paper is the proposed deep CNN architecture and the data augmentation technique, which is of paramount importance in the training process. The sliding window strategy for generating new training samples allowed the deep network architecture to learn efficiently even with reduced data.

Results showed that the proposed EEG-based biometric system can be a promising method for future real-world applications since researchers are developing hardware to facilitate embedding a CNN model, such FPGA-based deep learning acceleration and NVIDIA TX1⁵.

⁵ <http://www.nvidia.com/>

Acknowledgements

The authors thank UFOP and funding Brazilian agencies CNPq, Fapemig and CAPES. We gratefully acknowledge the support of NVIDIA Corporation with the donation of the Titan X Pascal GPU used for this research.

References

1. Collobert, R., Weston, J., Bottou, L., Karlen, M., Kavukcuoglu, K., Kuksa, P.: Natural language processing (almost) from scratch. *J. Mach. Learn. Res.* 12, 2493–2537 (Nov 2011), <http://dl.acm.org/citation.cfm?id=1953048.2078186>
2. Fraschini, M., Hillebrand, A., Demuru, M., Didaci, L., Marcialis, G.L.: An eeg-based biometric system using eigenvector centrality in resting state brain networks. *IEEE Signal Process. Lett.* 22(6), 666–670 (2015)
3. Goldberger, A.L., Amaral, L.A.N., Glass, L., Hausdorff, J.M., Ivanov, P.C., Mark, R.G., Mietus, J.E., Moody, G.B., Peng, C.K., Stanley, H.E.: PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals. *Circulation* 101(23), e215–e220 (2000 (June 13))
4. Jain, A.K., Ross, A., Prabhakar, S.: An introduction to biometric recognition. *IEEE Trans. Cir. and Sys. for Video Technol.* 14(1), 4–20 (Jan 2004)
5. Krizhevsky, A., Sutskever, I., Hinton, G.E.: Imagenet classification with deep convolutional neural networks. In: Proceedings of the 25th International Conference on Neural Information Processing Systems. pp. 1097–1105. NIPS’12, Curran Associates Inc., USA (2012), <http://dl.acm.org/citation.cfm?id=2999134.2999257>
6. Krizhevsky, A., Sutskever, I., Hinton, G.E.: Imagenet classification with deep convolutional neural networks. In: Pereira, F., Burges, C.J.C., Bottou, L., Weinberger, K.Q. (eds.) *Advances in Neural Information Processing Systems 25*, pp. 1097–1105. Curran Associates, Inc. (2012), <http://papers.nips.cc/paper/4824-imagenet-classification-with-deep-convolutional-neural-networks.pdf>
7. LeCun, Y., Bengio, Y., Hinton, G.: Deep learning. *Nature* 521(7553), 436–444 (2015)
8. Poulos, M., Rangoussi, M., Chrissikopoulos, V., Evangelou, A.: Person identification based on parametric processing of the EEG. In: *Electronics, Circuits and Systems, 1999. Proceedings of ICECS ’99. The 6th IEEE International Conference on*. vol. 1, pp. 283–286 (1999)
9. Reitermanov, Z.: Data splitting. In: *WDS’10 –Proceedings of Contributed Papers*. pp. 31–36 (2010)
10. Simonyan, K., Zisserman, A.: Very deep convolutional networks for large-scale image recognition. *CoRR* abs/1409.1556 (2014), <http://arxiv.org/abs/1409.1556>
11. Vedaldi, A., Lenc, K.: Matconvnet – convolutional neural networks for MATLAB. In: *Proceeding of the ACM Int. Conf. on Multimedia* (2015)
12. Yang, S., Deravi, F., Hoque, S.: Task sensitivity in EEG biometric recognition. *Pattern Analysis and Applications* pp. 1–13 (2016)
13. Zeiler, M.D., Fergus, R.: *Visualizing and Understanding Convolutional Networks*, pp. 818–833. Springer International Publishing, Cham (2014)

Referências Bibliográficas

- Acquarelli, J., Marchiori, E., Buydens, L. M. C., Tran, T. N. and van Laarhoven, T.: 2017, Convolutional neural networks and data augmentation for spectral-spatial classification of hyperspectral images, *CoRR* **abs/1711.05512**.
URL: <http://arxiv.org/abs/1711.05512>
- Batool, A. and Tariq, A.: 2011, Computerized system for fingerprint identification for biometric security, *2011 IEEE 14th International Multitopic Conference*, pp. 102–106.
- Boubakeur, M. R., Wang, G., Zhang, C. and Liu, K.: 2017, Eeg-based person recognition analysis and criticism, *2017 IEEE International Conference on Big Knowledge (ICBK)*, pp. 155–160.
- Cecotti, H., Eckstein, M. P. and Giesbrecht, B.: 2014, Single-trial classification of event-related potentials in rapid serial visual presentation tasks using supervised spatial filtering, *IEEE Transactions on Neural Networks and Learning Systems* **25**(11), 2030–2042.
- Clarke, R.: 1994, Human identification in information systems: Management challenges and public policy issues, *Information Technology & People* **7**(4), 6–37.
URL: <https://doi.org/10.1108/09593849410076799>
- Das, R., Maiorana, E. and Campisi, P.: 2017, Visually evoked potential for EEG biometrics using convolutional neural network, *25th European Signal Processing Conference, EUSIPCO 2017, Kos, Greece, August 28 - September 2, 2017*, pp. 951–955.
URL: <https://doi.org/10.23919/EUSIPCO.2017.8081348>
- Delorme, A., Sejnowski, T. and Makeig, S.: 2006, Technical note enhanced detection of artifacts in eeg data using higher-order statistics and independent component analysis.
- DeVries, T. and Taylor, G. W.: 2017, Dataset Augmentation in Feature Space, *ArXiv e-prints*.

- Du, Y. and Chang, C.-I.: 2007.
- Felleman, D. J. and Essen, D. C. V.: 1991, Distributed hierarchical processing in the primate cerebral cortex, *Cereb Cortex* pp. 1–47.
- Fraschini, M., Hillebrand, A., Demuru, M., Didaci, L. and Marcialis, G. L.: 2015, An eeg-based biometric system using eigenvector centrality in resting state brain networks, *IEEE Signal Process. Lett.* **22**(6), 666–670.
- Geisler, W. S. and Albrecht, D. G.: 1992, Cortical neurons: isolation of contrast gain control, *Vision Research* **32**(8), 2429–2454.
- Ghandeharion, H. and Ahmadi-Noubari, H.: 2009, Detection and removal of ocular artifacts using independent component analysis and wavelets, *2009 4th International IEEE/EMBS Conference on Neural Engineering*, pp. 653–656.
- Goldberger, A. L., Amaral, L. A. N., Glass, L., Hausdorff, J. M., Ivanov, P. C., Mark, R. G., Mietus, J. E., Moody, G. B., Peng, C.-K. and Stanley, H. E.: 2000, PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals, *Circulation* **101**(23), e215–e220.
- Hinton, G. E., Srivastava, N., Krizhevsky, A., Sutskever, I. and Salakhutdinov, R.: 2012, Improving neural networks by preventing co-adaptation of feature detectors, *CoRR* **abs/1207.0580**.
URL: <http://arxiv.org/abs/1207.0580>
- Hirose, Y., Yamashita, K. and Hijiya, S.: 1991, Back-propagation algorithm which varies the number of hidden units, *Neural Networks* **4**(1), 61 – 66.
URL: <http://www.sciencedirect.com/science/article/pii/089360809190032Z>
- Jain, A. K., Ross, A. and Prabhakar, S.: 2004, An introduction to biometric recognition, *IEEE Trans. Cir. and Sys. for Video Technol.* **14**(1), 4–20.
- K., R., N., S., Raja, K. B., R., V. K. and Patnaik, L. M.: 2009, Advanced biometric identification on face, gender and age recognition, *2009 International Conference on Advances in Recent Technologies in Communication and Computing*, pp. 23–27.
- Kostílek, M. and Št’astný, J.: 2012, Eeg biometric identification: Repeatability and influence of movement-related eeg, *2012 International Conference on Applied Electronics*, pp. 147–150.

- Krizhevsky, A., Sutskever, I. and Hinton, G. E.: 2012, Imagenet classification with deep convolutional neural networks, *Proceedings of the 25th International Conference on Neural Information Processing Systems*, NIPS'12, Curran Associates Inc., USA, pp. 1097–1105.
URL: <http://dl.acm.org/citation.cfm?id=2999134.2999257>
- Kumar, S., Arumuganathan, R., Sivakumar, K. and Vimal, C.: 2009, An adaptive method to remove ocular artifacts from eeg signals using wavelet transform, **5**.
- LeCun, Y., Bengio, Y. and Hinton, G.: 2015, Deep learning, *Nature* **521**(7553), 436–444.
- LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W. and Jackel, L. D.: 1989, Backpropagation applied to handwritten zip code recognition, *Neural Computation* **1**(4), 541–551.
- LeCun, Y., Bottou, L., Bengio, Y. and Haffner, P.: 1998, Gradient-based learning applied to document recognition, *Proceedings of the IEEE* **86**(11), 2278–2324.
- Lee, T. S., Mumford, D., Romero, R. and Lamme, V. A.: 1998, The role of the primary visual cortex in higher level vision, *Vision Research* **38**(15), 2429 – 2454.
URL: <http://www.sciencedirect.com/science/article/pii/S0042698997004641>
- Lumini, A. and Nanni, L.: 2017, Overview of the combination of biometric matchers, *Information Fusion* **33**, 71 – 85.
URL: <http://www.sciencedirect.com/science/article/pii/S1566253516300446>
- Ma, L., Minett, J. W., Blu, T. and Wang, W. S. Y.: 2015, Resting state eeg-based biometrics for individual identification using convolutional neural networks, *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pp. 2848–2851.
- Mao, Z., Yao, W. X. and Huang, Y.: 2017, Eeg-based biometric identification with deep learning, *2017 8th International IEEE/EMBS Conference on Neural Engineering (NER)*, pp. 609–612.
- Marcel, S. and Millan, J. d. R.: 2007, Person authentication using brainwaves (eeg) and maximum a posteriori model adaptation, *IEEE Trans. Pattern Anal. Mach. Intell.* **29**(4), 743–752.
URL: <http://dx.doi.org/10.1109/TPAMI.2007.1012>

- Martin, A., Doddington, G., Kamm, T., Ordowski, M. and Przybocki, M.: 1997, The det curve in assessment of detection task performance, pp. 1895–1898.
- Mohammadi, G., Shoushtari, P., Molaee Ardekani, B. and Shamsollahi, M. B.: 2006, Person identification by using ar model for eeg signals, *Proceeding of World Academy of Science, Engineering and Technology* **11**, 281–285.
- Palaniappan, R.: 2005, Identifying individuality using mental task based brain computer interface, *2005 3rd International Conference on Intelligent Sensing and Information Processing*, pp. 238–242.
- Palaniappan, R. and Mandic, D. P.: 2007a, Biometrics from brain electrical activity: A machine learning approach, *IEEE Transactions on Pattern Analysis and Machine Intelligence* **29**(4), 738–742.
- Palaniappan, R. and Mandic, D. P.: 2007b, Eeg based biometric framework for automatic identity verification, *J. VLSI Signal Process. Syst.* **49**(2), 243–250.
URL: <http://dx.doi.org/10.1007/s11265-007-0078-1>
- Paranjape, R. B., Mahovsky, J., Benedicenti, L. and Koles', Z.: 2001, The electroencephalogram as a biometric, *Canadian Conference on Electrical and Computer Engineering 2001. Conference Proceedings (Cat. No.01TH8555)*, Vol. 2, pp. 1363–1366 vol.2.
- Pinto, N. and Cox, D.: 2011, Beyond simple features: A large-scale feature search approach to unconstrained face recognition, *IEEE International Conference on Automatic Face Gesture Recognition and Workshops*, pp. 8–15.
- Poulos, M., Rangoussi, M., Chrissikopoulos, V. and Evangelou, A.: 1999a, Parametric person identification from the eeg using computational geometry, *Electronics, Circuits and Systems, 1999. Proceedings of ICECS '99. The 6th IEEE International Conference on*, Vol. 2, pp. 1005–1008 vol.2.
- Poulos, M., Rangoussi, M., Chrissikopoulos, V. and Evangelou, A.: 1999b, Person identification based on parametric processing of the EEG, *Electronics, Circuits and Systems, 1999. Proceedings of ICECS '99. The 6th IEEE International Conference on*, Vol. 1, pp. 283–286.
- Pozo-Banos, M. D., Alonso, J. B., Ticay-Rivas, J. R. and Travieso, C. M.: 2014, Electroencephalogram subject identification: A review, *Expert Systems with Applications*

41(15), 6537 – 6554.

URL: <http://www.sciencedirect.com/science/article/pii/S0957417414002930>

Rolls, E. and Deco, G.: 2002, *Computational Neuroscience of Vision*, Oxford University Press.

Rumelhart, D. E., Hinton, G. E. and Williams, R. J.: 1986, Learning representations by back-propagating errors, *Nature* **323**, 533–536. [ja href="absps/sutherlandbp.pdf">ja href="absps/sutherlandbp.pdf](#)»Commentary from News and Views section of Nature;aj.

Sadasivan, P. K. and Dutt, D. N.: 1995, Line interference cancellation from corrupted eeg signals using modified linear phase fir digital filters, *Proceedings of the First Regional Conference, IEEE Engineering in Medicine and Biology Society and 14th Conference of the Biomedical Engineering Society of India. An International Meet*, pp. 3/35–3/36.

Schons, T., Moreira, G. J. P., Silva, P. H. L., Coelho, V. N. and Luz, E. J. S.: 2018, Convolutional network for eeg-based biometric, in M. Mendoza and S. Velastín (eds), *Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications*, Springer International Publishing, Cham, pp. 601–608.

Simonyan, K. and Zisserman, A.: 2014, Very deep convolutional networks for large-scale image recognition, *CoRR* **abs/1409.1556**.

URL: <http://arxiv.org/abs/1409.1556>

Singh, B., Mishra, S. and Tiwary, U. S.: 2015, Eeg based biometric identification with reduced number of channels, *2015 17th International Conference on Advanced Communication Technology (ICACT)*, pp. 687–691.

Soni, Y. S., Somani, S. B. and Shete, V. V.: 2016, Biometric user authentication using brain waves, *2016 International Conference on Inventive Computation Technologies (ICICT)*, Vol. 2, pp. 1–6.

Stassen, H.: 1980, Computerized recognition of persons by eeg spectral patterns, *Electroencephalography and Clinical Neurophysiology* **49**(1), 190 – 194.

URL: <http://www.sciencedirect.com/science/article/pii/0013469480903685>

Subasi, A. and Ismail Gursoy, M.: 2010, Eeg signal classification using pca, ica, lda and support vector machines, *Expert Syst. Appl.* **37**(12), 8659–8666.

URL: <http://dx.doi.org/10.1016/j.eswa.2010.06.065>

- Tangkraingkiij, P., Lursinsap, C., Sanguansintukul, S. and Desudchit, T.: 2009, Selecting relevant eeg signal locations for personal identification problem using ica and neural network, *2009 Eighth IEEE/ACIS International Conference on Computer and Information Science*, pp. 616–621.
- Vedaldi, A. and Lenc, K.: 2015, Matconvnet – convolutional neural networks for MATLAB, *Proceeding of the ACM Int. Conf. on Multimedia*.
- Yang, S. and Deravi, F.: 2017, On the usability of electroencephalographic signals for biometric recognition: A survey, *IEEE Transactions on Human-Machine Systems* .
URL: <http://kar.kent.ac.uk/61551/>
- Yang, S., Deravi, F. and Hoque, S.: 2016, Task sensitivity in EEG biometric recognition, *Pattern Analysis and Applications* pp. 1–13.
- Yong, X., Ward, R. K. and Birch, G. E.: 2008, Robust common spatial patterns for eeg signal preprocessing, *2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp. 2087–2090.
- Zeiler, M. D. and Fergus, R.: 2014, *Visualizing and Understanding Convolutional Networks*, Springer International Publishing, Cham, pp. 818–833.