

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA**

LUCIANO BONGIORNI ALFF DE FREITAS

**AVALIAÇÃO DO USO DE REDES
NEURAIS RECORRENTES COMO
POSSÍVEL PREDITORA DE ATAQUES
EPILEPTICOS**

Porto Alegre

2019

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA**

LUCIANO BONGIORNI ALFF DE FREITAS

**AVALIAÇÃO DO USO DE REDES NEURAIS
RECORRENTES COMO POSSÍVEL PREDITORA
DE ATAQUES EPILÉTICOS**

Projeto de Diplomação apresentado ao Departamento de Engenharia Elétrica da Escola de Engenharia da Universidade Federal do Rio Grande do Sul, como requisito parcial para Graduação em Engenharia Elétrica

Orientador: Prof. Dr. Alexandre Balbinot

Porto Alegre

2019

LUCIANO BONGIORNI ALFF DE FREITAS

**AVALIAÇÃO DO USO DE REDES NEURAIS
RECORRENTES COMO POSSÍVEL PREDITORA
DE ATAQUES EPILÉTICOS**

Projeto de Diplomação apresentado ao Departamento de Engenharia Elétrica da Escola de Engenharia da Universidade Federal do Rio Grande do Sul, como requisito parcial para Graduação em Engenharia Elétrica

Prof. Dr. Alexandre Balbinot
Orientador - UFRGS

Aprovado em 15 de Março de 2019.

BANCA EXAMINADORA

Prof. Dr. Alexandre Balbinot
UFRGS

Prof. Dr. Jeferson Flores
UFRGS

Prof. Me. Juliano Machado
UFRGS

Aos meus pais que tanto me apoiaram em tudo
que eu quisesse de verdade e que prestaram o
melhor exemplo possível de conduta humana.

AGRADECIMENTOS

Aos meus pais que me apoiaram de diversas formas para realizar esse trabalho e me estimularam desde cedo a buscar minha evolução intelectual e pessoal.

À Julia Hashiguchi que teve toda paciência e compreensão para suportar minha ausência, e que me fez feliz a cada instante juntos, tornando a vida ainda melhor.

Ao Prof. Dr. Alexandre Balbinot pela orientação e preocupação empregada para a realização de um trabalho significativo.

*If something is important enough,
you should try.
Even if the probable outcome is failure.*

Elon Musk

RESUMO

A ocorrência de ataques epiléticos é um problema que dificulta o cotidiano de muitas pessoas que sofrem dessa desordem, podendo causar riscos ao indivíduo e às pessoas à sua volta. A possibilidade de predição de ataques epiléticos poderia trazer uma forma de minimizar os riscos associados a esses ataques. Dado que a epilepsia tem origem em atividades anormais de sinais cerebrais, uma forma de monitoramento desses sinais e, conseqüentemente, da ocorrência de ataques epiléticos, é a Eletroencefalografia. Através da análise computacional desses dados se desenvolveu uma variação de Rede Neural Artificial Recorrente do tipo *Long Short Term Memory* de forma a classificar segmentos de sinais de Eletroencefalografia que indiquem a iminência da ocorrência de um evento epilético, segmentos que representam o denominado estado pré-ictal. Com a utilização de uma base de dados de Eletroencefalografia de indivíduos epiléticos obtida no *Children's Hospital Boston* pela base de dados Physionet, foram criados grupos de pacientes, então selecionados os canais de Eletroencefalografia em comum e reduzidos para apenas 25% desses com base em estudos sobre redução de canais na determinação de eventos epiléticos. Foram extraídas características temporais e espectrais, sendo elas o valor médio quadrático, desvio padrão, número de picos observados acima de um limiar, Transformada Rápida de Fourier e densidade espectral de potência. Além de utilizar os dados obtidos, foram propostas três técnicas de manipulação de dados, sendo a primeira técnica a sobreposição de dados de entrada de treinamento, a segunda técnica propôs o deslocamento dos valores alvo de treinamento para demarcar manualmente regiões pré-ictais, e a última técnica consistiu na união das duas primeiras. Utilizando os dados de Eletroencefalografia e características extraídas dos mesmos, foi treinada a Rede Neural utilizando a estrutura básica e as três técnicas propostas. Se obteve taxas de acerto da Rede Neural de mais de 99%, entretanto os resultados demonstraram que com a metodologia proposta não foi possível classificar regiões pré-ictais, além da Rede Neural ser fortemente dependente dos padrões de Eletroencefalografia do paciente analisado. Apesar disso se observou que a Rede Neural conseguiu classificar regiões ictais com até 61% de *sensitivity* (taxa de verdadeiros positivos) e até 99% de *specificity* (taxa de verdadeiros negativos), demonstrando a capacidade de Redes Neurais Recorrentes do tipo *Long Short Term Memory* de apreenderem padrões temporais.

Palavras-chave: epilepsia; predição categórica; redes neurais recorrentes (RNR); *Long Short Term Memory* (LSTM); Eletroencefalografia (EEG); diagnóstico inteligente.

ABSTRACT

The occurrence of epileptic seizures is a problem that makes everyday life difficult for many people who suffer from this disorder, may causing risks to the subjects and people around them. The possibility of predicting epileptic seizures could bring a way to minimize the risks associated to these attacks. Given the epilepsy has its origins in abnormal activity of brain signals, a way to monitor these signals and, consequently, the occurrence of epileptic seizures, is the Electroencephalography. Through computational analysis of these data, a variation of Recurrent Artificial Neural Network of Long Short Term Memory type was developed in such a way to try to classify segments of signals of Electroencephalography that point to the imminence of the occurrence of an epileptic seizure, segments which evince the named pre-ictal state. Using a Electroencephalography database of epileptic individuals collected at the Children's Hospital Boston by the Physionet database, groups of patients were created, then Electroencephalography channels in common were selected and reduced by only 25% based on studies about channel reduction in determination of epileptic events. Temporal and spectral characteristics were extracted, being these the root mean square, standard deviation, number of peaks observed above a threshold, Fast Fourier Transform and power spectral density. Besides using the obtained data, three data manipulation techniques were proposed, being the first technique the superposition of input training data, the second technique proposed the shift of training target values to manually mark pre-ictal regions, and the last technique consisted in the union of the first two. Using the Electroencephalography data and characteristics extracted from these, the Neural Network was trained using the basic structure and the three proposed techniques. High accuracies above 99% were obtained from the Neural Network, however the results showed that it wasn't possible to classify pre-ictal regions by using the proposed methodology, in addition to a strong dependency observed between the Neural Network performance and the Electroencephalographic patterns of analyzed patients. Beyond that it was observed that the Neural Network managed to classify ictal regions with up to 61% sensitivity (true positive rate) and up to 99% specificity (true negative rate), showing the capacity of Recurrent Neural Networks of Long Short Term type to assimilate temporal patterns.

Keywords: epilepsy; categorical prediction; Recurrent Neural Networks (RNN); LSTM; Electroencephalography (EEG); intelligent diagnosis.

LISTA DE FIGURAS

Figura 1 – Encéfalo e suas divisões. Corte longitudinal. Vista lateral direita. . . .	17
Figura 2 – Áreas funcionais do córtex cerebral segundo a citoarquitetura de Brodmann, denotadas pelas regiões contidas entre as linhas azuis. Vista lateral esquerda.	18
Figura 3 – Lobos do Cérebro. Vista lateral direita.	19
Figura 4 – Pontos definidos pelo Sistema Internacional 10-20: (a) vista lateral esquerda. (b) vista superior.	21
Figura 5 – Sistema 10-20 com nomenclatura alterada. Os pontos com nomes alterados são T7, T8, P7 e P8, os quais se encontram em destaque.	22
Figura 6 – RNN e sua equivalência de funcionamento como muitas camadas neurais.	29
Figura 7 – Arquitetura típica de uma rede recorrente do tipo LSTM.	31
Figura 8 – Diagrama de blocos da estrutura principal do trabalho.	34
Figura 9 – Diagrama de classes dos arquivos com extensão JSON criados a partir dos dados de marcação de tempo disponibilizados pela base de dados.	40
Figura 10 – Diagrama de atividades do algoritmo de tratamento de dados utilizado para adequação dos arquivos utilizados no treinamento da rede neural.	41
Figura 11 – Etapas de pré-processamento adotadas.	44
Figura 12 – STFT de um sinal de EEG juntamente com a marcação da ocorrência de eventos epiléticos registrados. Ilustração das variações temporais e espectrais características de eventos epiléticos.	47
Figura 13 – Análise espectral de regiões inter-ictais, pré-ictais e ictais do canal F7-T7 com o uso de STFT. Exibição gráfica da leitura de EEG dos quatro canais selecionados para o trabalho.	48
Figura 14 – Divisão dos conjuntos de dados em lotes e observações.	53
Figura 15 – Sobreposição de dados de entrada (sinal superior) através da aplicação de janelas deslizantes de tamanho W e passo S , obtendo sinal com sobreposição (sinal inferior). Diferentes tracejados indicam diferentes janelas. Procedimento aplicado aos conjuntos de treinamento para antecipação das predições de eventos epiléticos.	54
Figura 16 – Deslocamento de alvos para antecipação das predições de ataques epiléticos: (a) alvos originais e (b) alvos deslocados.	55
Figura 17 – Divisão dos conjuntos de dados de entrada e alvos em lotes e observações.	56
Figura 18 – Diagrama da ANN LSTM desenvolvida para classificação categórica de sinais temporais de EEG entre inter-ictal e pré-ictal. Representação do fluxo de dados para um único lote. O número em cada camada indica o número de células ou neurônios: (a) diagrama da arquitetura geral e (b) diagrama da arquitetura para sobreposição de dados.	58

Figura 19 – Variação da taxa de acerto e da perda da ANN conforme o número de épocas.	61
Figura 20 – Exemplos de predições sem antecipação, ambos arquivos analisados apresentam eventos epiléticos no final dos mesmos. Apesar de não classificarem com antecipação, as predições indicam corretamente a ocorrência de eventos epiléticos. Presença de falsos positivos: (a) no início do arquivo pertencente ao grupo 1 e (b) no final do arquivo pertencente ao grupo 3, logo após o evento epilético.	63
Figura 21 – Matrizes de confusão da determinação de períodos ictais para todos grupos de treinamento utilizando estrutura de treinamento básica. . . .	65
Figura 22 – Picos de detecção dentro de uma janela de ocorrência de um evento epilético. Trechos sem detecção se refletem na <i>sensitivity</i> da rede. . . .	66
Figura 23 – Exemplo dos resultados obtidos com sobreposição de dados para arquivos do grupo 1 e 3. Há uma ocorrência de evento epilético ao final de cada arquivo, onde se encontram muitos picos de detecção. A <i>sensitivity</i> apresenta bons resultados em detrimento da <i>specificity</i> , resultado evidenciado por muitos falsos positivos. Os eventos epiléticos são demarcados por setas para melhor identificação. (a) arquivo do grupo 3, cujo evento epilético se encontra entre 3000 e 3500 segundos, encoberto por diversos picos de detecção. (b) arquivo do grupo 1, com clara classificação do período ictal entre 2500 e 3000 segundos.	68
Figura 24 – Representação visual dos resultados obtidos com variação do tempo de antecipação de alvos de treinamento para o grupo de pacientes 1. . . .	71

LISTA DE TABELAS

Tabela 1	–	Típicas ondas cerebrais com suas correspondentes faixas de frequência.	21
Tabela 2	–	Relação desbalanceada de pacientes dispostos em ordem decrescente de quantidade de arquivos com eventos epiléticos registrados em cada caso. Os pacientes estão agrupados em três categorias genéricas para melhor distinção da densidade de eventos epiléticos.	36
Tabela 3	–	Relação dos canais para cada arquivo de casos selecionados, evidenciando o desbalanceamento de canais da base de dados.	38
Tabela 4	–	Agrupamento de pacientes de forma aleatorizada para realização de treinamento sem viés de seleção. Grupos enumeram pacientes com diferentes densidades de eventos epiléticos num mesmo período de tempo, evidenciando possíveis diferenças de padrões de atividades cerebrais. . .	39
Tabela 5	–	Organização dos arquivos utilizados nas redes neurais do presente trabalho. Tempo decorrido desde o início da gravação, canais de leitura de diferença de potencial em microvolts com identificação dos pontos do Sistema Internacional 10-20 utilizado, e coluna final indicando se durante a gravação do dado estava ocorrendo um ataque epilético. . . .	43
Tabela 6	–	Combinações de canais de EEG para predição de eventos epiléticos com taxas de acerto iguais ou maiores que a taxa de acerto utilizando 22 canais.	46
Tabela 7	–	Performance da ANN conforme o número de épocas de treinamento utilizadas. Testes feitos com estrutura básica da ANN e grupo de treinamento 1.	61
Tabela 8	–	Percentual de detecção antecipada de eventos epiléticos considerando todas as técnicas propostas e variando o tamanho do período pré-ictal. Resultados obtidos para cada grupo de pacientes e para todo o conjunto de grupos.	62
Tabela 9	–	Resultados obtidos com estrutura básica de treinamento.	66
Tabela 10	–	Resultados obtidos com técnica de sobreposição de dados com janelas deslizantes.	67
Tabela 11	–	Comparação de resultados resultantes da variação do tamanho da janela e do passo de sobreposição aplicados aos dados de treinamento. Teste realizado com grupo de pacientes 1.	69
Tabela 12	–	Resultados obtidos com técnica de antecipação de alvos no conjunto de treinamento.	70
Tabela 13	–	Resultados obtidos ao se varia o tempo de antecipação de alvos de treinamento para o grupo de pacientes 1.	70
Tabela 14	–	Resultados obtidos com técnica de sobreposição de dados e antecipação de alvos no conjunto de treinamento.	72

LISTA DE ABREVIATURAS

AUROC	<i>Area Under the Receiver Operating Characteristic Curve</i>
ANN	<i>Artificial Neural Network</i>
ARMA	<i>Autoregressive Moving Average</i>
BPTT	<i>Backpropagation Through Time</i>
CNN	<i>Convolutional Neural Networks</i>
CNS	<i>Central Nervous System</i>
CSV	<i>Comma Separated Values</i>
DFT	<i>Discrete Fourier Transform</i>
EDF	<i>European Data Format</i>
EEG	<i>Electroencephalography</i>
ELM	<i>Extreme Learning Machine</i>
FFT	<i>Fast Fourier Transform</i>
GRU	<i>Gated Recurrent Unit</i>
iEEG	<i>Intracranial Electroencephalography</i>
JSON	<i>JavaScript Object Notation</i>
LSTM	<i>Long Short-Term Memory</i>
MLFFN	<i>Multilayer Feed Forward Neural Network</i>
PSD	<i>Power Spectral Density</i>
RMS	<i>Root Mean Square</i>
RNN	<i>Recurrent Neural Network</i>
STFT	<i>Short Time Fourier Transform</i>
SVM	<i>Support Vector Machine</i>

SUMÁRIO

1	INTRODUÇÃO	13
2	REVISÃO BIBLIOGRÁFICA	16
2.1	UMA BREVE INTRODUÇÃO À ANATOMIA E FISIOLÓGIA DO CÉREBRO HUMANO	16
2.2	ELETROENCEFALOGRAFIA	19
2.3	EPILEPSIA E SEUS MÉTODOS USUAIS DE PREDIÇÃO	23
2.4	REDES NEURAIS ARTIFICIAIS	27
2.4.1	Redes Neurais Recorrentes	28
2.4.2	Redes Recorrentes do tipo LSTM	30
3	METODOLOGIA EXPERIMENTAL	34
3.1	BANCO DE DADOS	35
3.2	TRATAMENTO DE DADOS	40
3.3	PRÉ-PROCESSAMENTO DE DADOS	43
3.3.1	Redução de canais	44
3.3.2	Extração de características	47
3.3.3	Normalização de dados e categorização de alvos	52
3.3.4	Sobreposição de dados de entrada e mudança de valores alvo	54
3.4	REDE RECORRENTE LSTM	55
4	RESULTADOS E DISCUSSÕES	60
4.1	AVALIAÇÃO DA PERFORMANCE E PREDIÇÕES DA REDE NEURAL	60
4.2	TREINAMENTO COM ESTRUTURA BÁSICA	64
4.3	TREINAMENTO COM SOBREPOSIÇÃO DE DADOS	67
4.4	TREINAMENTO COM ANTECIPAÇÃO DE ALVOS	70
4.5	TREINAMENTO COM SOBREPOSIÇÃO DE DADOS E ANTECIPAÇÃO DE ALVOS	72
5	CONCLUSÕES	74
6	PROPOSTAS PARA TRABALHOS FUTUROS	75
	REFERÊNCIAS BIBLIOGRÁFICAS	76

1 INTRODUÇÃO

Epilepsia é uma desordem caracterizada por atividade excessiva anormal do Cérebro, observável através dos sinais bioelétricos neurais. A epilepsia pode acarretar em ataques epiléticos, eventos nos quais o indivíduo epilético experimenta alterações sensoriais e/ou motoras, comumente acompanhado de graves dores devidas a contrações musculares involuntárias (SIULY; LI; ZHANG, 2016) (SHORVON *et al.*, 2013). Sendo os eventos epiléticos decorrentes de um funcionamento anormal de sinais bioelétricos neurais, os quais por definição são de natureza elétrica, a caracterização quantitativa de tais eventos se dá através da leitura dos sinais em questão por meio da Eletroencefalografia (EEG), o que permite a observação e manipulação dos dados por computadores de forma a se extrair informações úteis para monitoramento e tratamento de pessoas que apresentem essa desordem.

Sem um devido monitoramento as consequências indesejadas da epilepsia podem causar grande risco ao indivíduo e às pessoas à sua volta (KERR; NIXON; ANGALAKU-DITI, 2011) (BROMFIELD; CAVAZOS; SIRVEN, 2006), como por exemplo, em casos de operação de veículos, ferramentas, produtos perigosos, dentre outras situações onde a perda de consciência e controle muscular sejam essenciais, ou ainda em ambientes ambulatoriais, onde normalmente o indivíduo está conectado a aparelhos e máquinas sensíveis a movimentos bruscos. Portanto, o desenvolvimento de sistemas para predição de eventos epiléticos pode minimizar os riscos associados a esses eventos.

Existem diversas formas de predição de ataques epiléticos, as quais variam da própria análise clínica até o monitoramento de sinais musculares (VANDECASTEELE *et al.*, 2017). Dentre essas formas de predição, uma técnica computacional inteligente é a predição através do uso de Redes Neurais Artificiais (RNA) ou *Artificial Neural Networks* (ANNs) com dados obtidos por EEG, a qual já foi empregada com enfoque na extração de características e classificação de dados, e também com enfoque na arquitetura de Rede Neural (GUPTA; SINGH; KARLEKAR, 2018) (LARMUSEAU; DAMBRE, 2016) (SHOEB; GUTTAG, 2010). Uma ANN é um algoritmo de processamento de sinais que tenta emular de forma aproximada a transmissão de dados realizada por neurônios cerebrais, permitindo um sinal de entrada percorrer diversos caminhos influenciados por nódulos ou neurônios artificiais, os quais possuem pesos que podem ser alterados através do treinamento da rede, de forma a aproximar a saída pretendida conforme a entrada de dados. Tal treinamento atribui uma característica ao algoritmo de generalizar e classificar padrões de sinais que dificilmente seriam identificados analiticamente por equações ou algoritmos matemáticos clássicos (SHETA; AHMED; FARIS, 2015), como por exemplo, os sinais cerebrais que apresentam caráter fortemente estocástico. Essa capacidade de atualização de pesos atribui a eles o que ficou conhecido como inteligência computacional, ou seja, de forma simplificada é como a ANN aprende.

Uma classe especial de ANN é a Rede Neural Recorrente ou *Recurrent Neural Network* (RNN), a qual possui estrutura interna com realimentação de dados. Esse tipo de ANN consegue armazenar informações referentes a entradas que já foram analisadas, estabelecendo classificações que consideram não somente a entrada atual mas sim uma sequência de entradas (GOODFELLOW; BENGIO; COURVILLE, 2016), sendo portanto uma estrutura adequada para análise de sinais temporais. De forma a tratar apropriadamente de sequências temporais longas com menor perda de informações e sem extrapolação de dados, uma topologia de RNN chamada de Longa Memória de Curto Prazo ou *Long Short-Term Memory* (LSTM) soluciona esse problema (HOCHREITER; SCHMIDHUBER, 1997), estabelecendo uma estrutura adequada para tratamento de longas sequências de dados.

Através do emprego de algoritmos da área de inteligência computacional é possível minimizar erros humanos na análise de sinais relacionados a eventos epiléticos, e implementar um processo de avaliação de sinais neurológicos que apresente generalização na caracterização de eventos de interesse em diferentes indivíduos, assim podendo auxiliar profissionais da área da saúde no tratamento de tais indivíduos, além de embarcar inteligência artificial em sistemas de diagnóstico automáticos. Caso os algoritmos possam abstrair a variação estocástica inerente a sinais cerebrais (KLONOWSKI, 2007) obtidos por EEG, pode ser feita uma comparação condizente e classificação dos sinais lidos de forma a apontar a ocorrência de eventos que permitam prever a ocorrência de eventos de epilepsia. Assim sendo, este trabalho parte da hipótese que através da análise e classificação apropriadas de sinais cerebrais de indivíduos, seja possível prever e informar a ocorrência de eventos epiléticos futuros, permitindo ao próprio indivíduo epilético, familiares e/ou profissionais da área da saúde responsáveis pelo indivíduo a tomarem ações apropriadas com uma certa antecedência ao evento epilético. Portanto, a predição da ocorrência de eventos epiléticos através de métodos computacionais inteligentes tem o potencial de ajudar tais pessoas afetadas direta ou indiretamente por ataques epiléticos a agirem de forma a minimizar os riscos associados a esses eventos.

Este trabalho é apresentado através da divisão dos assuntos em capítulos. No Capítulo 2, é apresentada uma breve revisão bibliográfica abrangendo anatomia e fisiologia do Cérebro humano, Eletroencefalografia, epilepsia e seus métodos de predição, e por fim Redes Neurais Artificiais. O Capítulo 3 contém os detalhes da metodologia experimental adotada na implementação do trabalho, desde o estudo do banco de dados e seleção dos mesmo, até o pré processamento e desenvolvimento da ANN LSTM. Os resultados e discussões gerados a partir da implementação e testes de todos os blocos detalhados no capítulo anterior são apresentados no Capítulo 4, e as conclusões finais do trabalho estão contidas no Capítulo 5. No Capítulo 6 são apresentadas algumas possibilidades de continuidade futura para o correspondente trabalho.

Considerando-se os apontamentos anteriormente apresentados de forma resumida, este trabalho se dedica à implementação e investigação da eficácia de técnicas específicas de algoritmos de redes neurais na predição de eventos epiléticos. De forma mais específica, os objetivos consistem em:

- analisar uma base de dados de EEG com ocorrência de eventos epiléticos de indivíduos que apresentem epilepsia recorrente;
- analisar a extração de características matemáticas que apresentem correlações suficientemente significativas para determinação de regiões pré-ictais;
- desenvolver um algoritmo com ANN LSTM para predição antecipada de eventos epiléticos;
- analisar a latência do algoritmo em determinar eventos epiléticos.

2 REVISÃO BIBLIOGRÁFICA

2.1 UMA BREVE INTRODUÇÃO À ANATOMIA E FISIOLOGIA DO CÉREBRO HUMANO

O Cérebro controla e monitora todas ações do corpo humano, em uma estrutura complexa, utilizando do Sistema Nervoso Central ou *Central Nervous System* (CNS) como principal ponto de centralização para realização das funções cognitivas e motoras necessárias no nosso dia a dia. Dado que é o ponto central da origem dos eventos epiléticos, por estes serem devido a uma perturbação no funcionamento cerebral (SHORVON *et al.*, 2013), se faz necessário conhecer sua estrutura e funcionamento.

As ações do corpo humano, desde as atividades autônomas dos órgãos e percepção do mundo externo, até a atividade intelectual e emocional, são controladas ou intermediadas pelo Sistema Nervoso Central, devido à interação de células nervosas, também denominadas de neurônios (STANDRING, 2010). O CNS é constituído da medula espinhal e do Encéfalo, sendo este último composto pelo Cérebro e o Cerebelo. É através desse sistema que ocorrem as interações nervosas dos neurônios, em especial transmitindo comandos desde o Encéfalo até músculos e glândulas através de nervos cranianos e espinhais (STANDRING, 2010) (TORTORA, 2000).

O sistema nervoso possui os neurônios como agentes responsáveis pela assimilação e transmissão de informações, permitindo através da interação de uns com os outros e com tecidos do corpo humano, a conexão entre sensações físicas e pensamentos com a ação fisiológica apropriada (STANDRING, 2010).

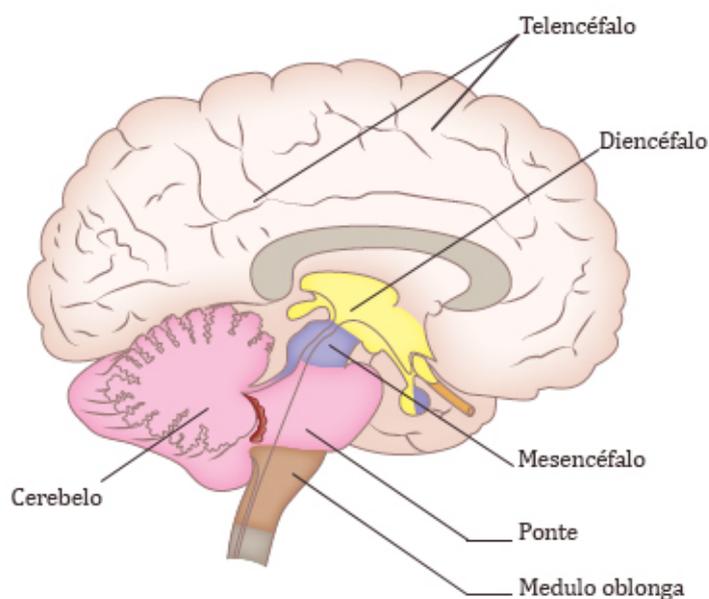
Neurônios são células nervosas constituídas principalmente de um corpo celular, dendritos e um axônio. Os dendritos e axônios são responsáveis pela transmissão de informações desde o corpo celular até demais pontos. No escopo da anatomia de um único neurônio os dendritos são diversos em quantidade, enquanto que o axônio é único, tendo o axônio uma grande extensão em relação aos dendritos (TORTORA, 2000). Os axônios podem possuir diversas terminações, as quais permitem realizar a transmissão de impulsos nervosos através do contato denominado de sinapse, que pode se dar com outros axônios, dendritos ou ainda até mesmo com o corpo celular.

A capacidade de geração de impulsos nervosos dos neurônios parte do princípio de que o interior do corpo celular se encontra ao potencial elétrico de -70 mV, tendo como referência o exterior. As substâncias neurotransmissoras presentes nos neurônios possibilitam a existência de um caminho elétrico para formação das sinapses, formando assim a capacidade de haver uma reação elétrica na ocorrência de excitação de um neurônio (STANDRING, 2010).

Uma região que contém grande concentração de neurônios está localizada na parte geometricamente superior do CNS, contida no crânio, e é denominada de Encéfalo. As suas divisões principais são o tronco do Encéfalo (constituído pela Ponte, Medula Oblonga

e Mesencéfalo), Cerebelo e Cérebro (constituído pelo Diencéfalo e Telencéfalo), como visto na Figura 1.

Figura 1 – Encéfalo e suas divisões. Corte longitudinal. Vista lateral direita.



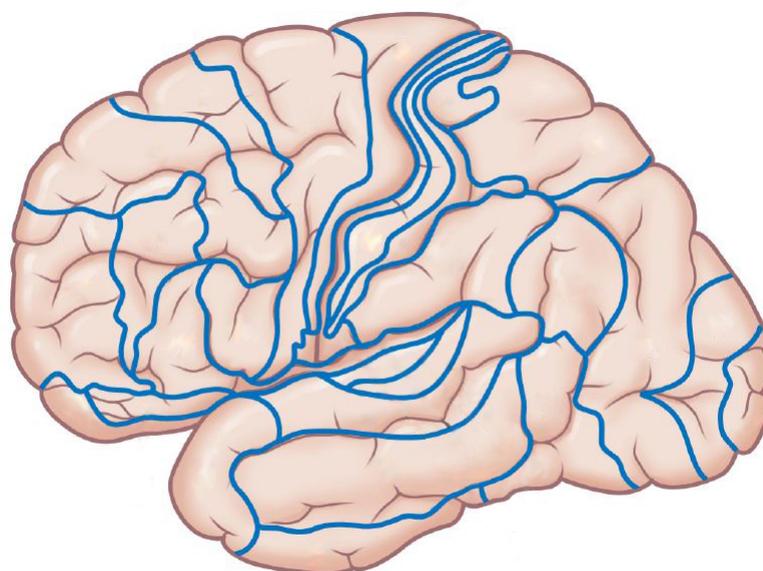
Fonte: Adaptado de (TORTORA, 2000).

O Encéfalo é um órgão composto de cerca de 100 bilhões de neurônios, havendo no Encéfalo (assim como no restante do CNS) agrupamentos de corpos celulares (parte central dos neurônios) que formam núcleos, sendo o conjunto maior de núcleos denominados de substância cinzenta (STANDRING, 2010) (TORTORA, 2000).

O córtex cerebral é a denominação dada à região mais externa do Encéfalo, região constituída de substância cinzenta e que apresenta grande concentração de neurônios, o que significa ser uma região rica em eventos sinápticos e portanto em processamento e interpretação de informações. A partir de uma divisão longitudinal do Cérebro, se obtém dois hemisférios, o esquerdo e o direito, sendo cada um responsável pelo controle das ações do lado oposto do corpo (por exemplo, o lado direito do Cérebro controla os movimentos motores do lado esquerdo do corpo). Cada hemisfério tem sua camada de córtex cerebral dividida em áreas corticais, sendo cada área referente a conjuntos de núcleos que dizem respeito ao controle de funções comuns do corpo humano (SIJLY; LI; ZHANG, 2016), tanto mecânicas, como o movimento executado pelo tensionamento muscular, quanto psíquicas, como o raciocínio. A partir do mapeamento de tais regiões ou áreas corticais, pode-se realizar a leitura de sinais denominados eletroencefalográficos, configurando-se assim a obtenção do EEG.

Diversas sub-divisões do Cérebro são mais ativamente responsáveis por cada tipo de funções exercidas pelo corpo humano, em especial as situadas no córtex cerebral devido à grande concentração de massa cinzenta. De forma a classificar as áreas funcionais do córtex cerebral responsáveis por determinadas atividades, é amplamente conhecida e difundida a citoarquitetura de Brodmann, a qual pode ser vista na Figura 2. Essa citoarquitetura define 52 áreas (nem todas apresentadas na Figura 2) de interesse para divisão funcional das atividades cerebrais.

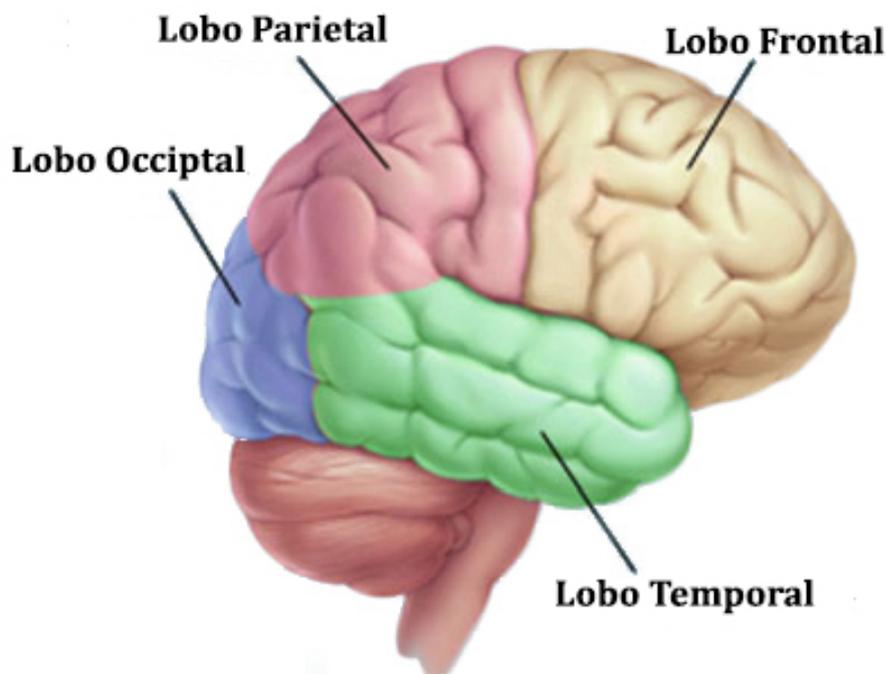
Figura 2 – Áreas funcionais do córtex cerebral segundo a citoarquitetura de Brodmann, denotadas pelas regiões contidas entre as linhas azuis. Vista lateral esquerda.



Fonte: Adaptado de (STANDRING, 2010).

As áreas funcionais do córtex cerebral são normalmente agrupadas em lobos, que podem ser vistos em melhores detalhes na Figura 3. Esses agrupamentos não levam em consideração somente a sua disposição geométrica das áreas funcionais mas também a sua funcionalidade (STANDRING, 2010), e esse se faz um ponto relevante caso se queiram medir os sinais com eletrodos posicionados ao longo da superfície do escalpo ou do próprio Cérebro.

Figura 3 – Lobos do Cérebro. Vista lateral direita.



Fonte: Adaptado de (SIULY; LI; ZHANG, 2016).

Os lobos cerebrais são divididos em quatro grandes grupos, cada grupo contendo diversos dos pontos indicados por Brodmann, o que pode ser melhor visualizado ao se comparar as Figuras 2 e 3. Estes lobos contêm pontos associados a funções distintas, observando-se que, segundo (STANDRING, 2010), cada área possui conexões com as demais, e é de grande importância saber qual lobo se observar conforme o tipo de função que se esteja monitorando, como por exemplo: ao se monitorar a resposta de um paciente a estímulos que causem dor, o lobo parietal seria o que apresentaria atividade mais significativa por conter os pontos da área somatossensitiva, ou seja, que dizem respeito a informações referentes a sensações em geral, como os sentidos de dor e tato (SIULY; LI; ZHANG, 2016) (TORTORA, 2000).

2.2 ELETROENCEFALOGRAFIA

Através das transmissões de impulsos elétricos, são gerados campos elétricos, dos quais pode-se obter potenciais elétricos, também chamados de ondas cerebrais, sendo situadas na ordem de magnitude de microvolts e de duração na ordem de milissegundos (NUNEZ; SRINIVASAN, 2006). Essas ondas cerebrais, quando apropriadamente mensuradas, podem prover um meio elétrico de verificar a intensidade, formato e variação da atividade cerebral ocorrendo no córtex cerebral, por fim permitindo relacionar tais ondas com os processos fisiológicos que estejam ocorrendo.

Um meio não invasivo para obtenção de tais sinais é a eletroencefalografia de escalpo, a qual consiste na utilização de eletrodos para apropriada captação dos potenciais elétricos para posterior filtragem e manipulação dos dados, a qual é, segundo (NUNEZ; SRINIVASAN, 2006), "uma importante ferramenta clínica para monitoramento e tratamento de certas doenças. Tumores cerebrais, derrames, epilepsias, doenças infecciosas [...] são algumas das condições médicas que podem aparecer em um EEG espontâneo".

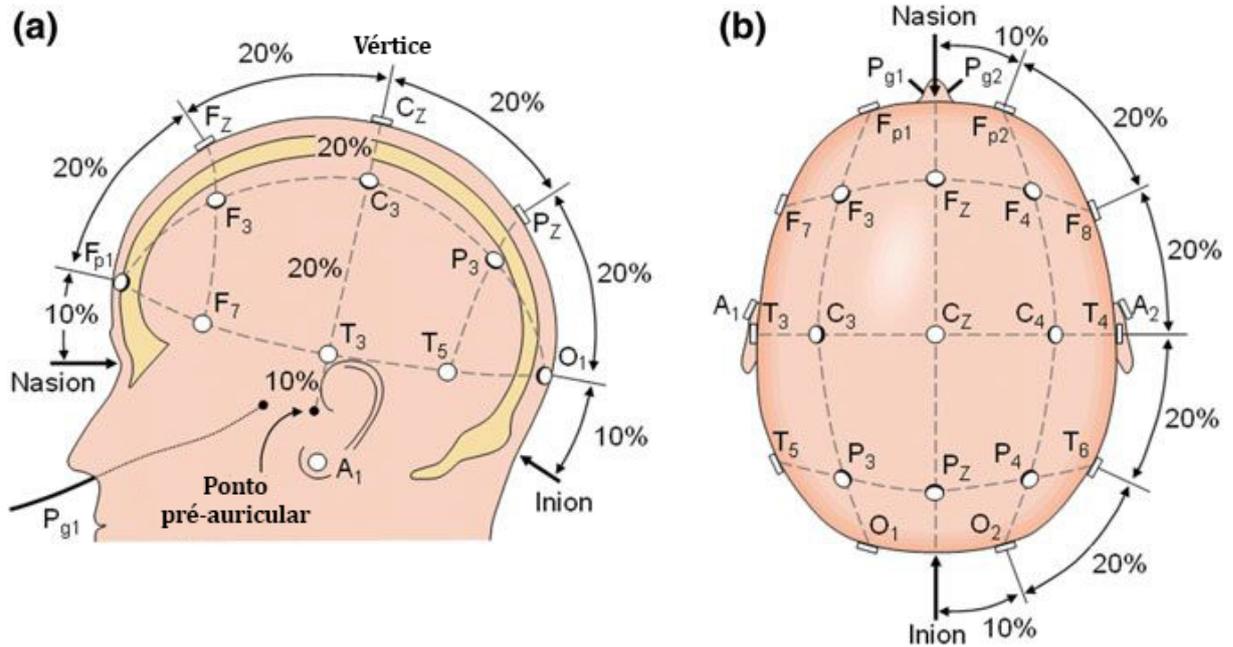
Os eletrodos utilizados na eletroencefalografia de escalpo são terminais elétricos aplicados de forma a prover um meio elétrico com baixa impedância para captação com o mínimo de perdas e distorção do sinal elétrico proveniente dos campos elétricos corticais. Tais terminais são geralmente utilizados em conjunto com géis que melhoram a condutividade elétrica entre o terminal e o escalpo (NUNEZ; SRINIVASAN, 2006) (NIEDERMEYER; SILVA, 1993).

Sabendo-se o modo de medição de ondas cerebrais, resta o problema de determinação de quantos terminais seriam apropriados para eficientemente mensurar a atividade cerebral cortical. Para tanto é geralmente empregado em EEG o Sistema Internacional de Eletrodos 10-20, o qual faz alusão ao método de separação entre os eletrodos na ordem de 10% ou 20% de distância em relação à distância entre a parte posterior do crânio até a parte frontal, ou do lado esquerdo ao direito do crânio (KLEM *et al.*, 1999). O ponto da parte posterior do crânio é situado na base do mesmo, na junção que faz com o pescoço, situado no ponto médio dessa junção, sendo esse ponto chamado de inion. Já o ponto da parte frontal é situado entre a testa e o nariz, no ponto médio à altura dos olhos, sendo esse ponto denominado de nasion (SIJLY; LI; ZHANG, 2016). Os pontos do Sistema Internacional 10-20, assim como, os pontos de referência inion e nasion, podem ser observados na Figura 4, com a correspondente separação percentual entre eles.

Tendo em vista as divisões em lobos cerebrais, o Sistema 10-20 determina que a divisão dos pontos para colocação dos terminais é composto de uma letra e um número, sendo a letra referente à primeira letra do nome do lobo cerebral e o número identificando em qual hemisfério cerebral se situa, sendo números pares referentes ao hemisfério direito e números ímpares ao hemisfério esquerdo (vide Figura 4). A exceção a esse padrão letra-número ocorre em pontos situados na fissura longitudinal do Cérebro, os quais são compostos pela primeira letra do lobo seguido do subscrito 'z' (SIJLY; LI; ZHANG, 2016). Esse conjunto de nomenclaturas e posicionamento de eletrodos determina a padronização para que os dados de EEG possam ser interpretados e comparados devidamente entre indivíduos.

É importante notar que o Sistema 10-20 permite a utilização de pontos adicionais intermediários localizados a 10% das distâncias transversais e longitudinais do crânio. Conforme padronizado pela *American Electroencephalographic Society* alguns pontos podem sofrer diferença de nomes em uma tentativa de empregar uma nomenclatura mais

Figura 4 – Pontos definidos pelo Sistema Internacional 10-20: (a) vista lateral esquerda. (b) vista superior.



Fonte: Adaptado de (SIULY; LI; ZHANG, 2016).

consistente (SHARBROUGH *et al.*, 1991) (KLEM *et al.*, 1999), sendo esses pontos T7, T8, P7 e P8, os quais são mostrados em destaque na Figura 5.

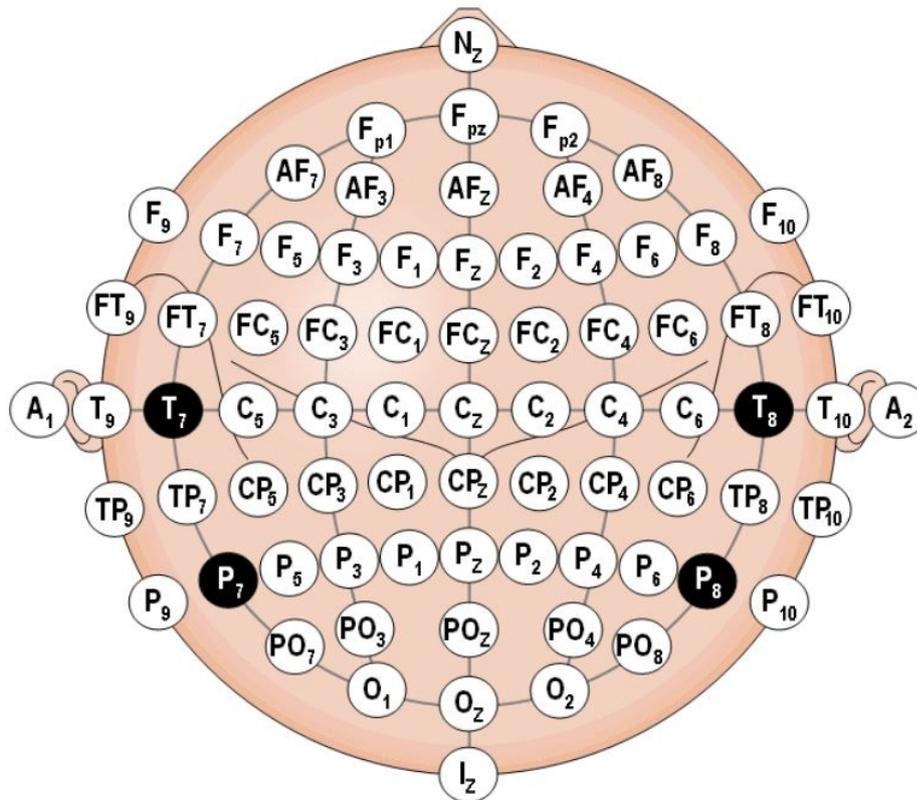
Através da realização de medições dos sinais cerebrais com EEG ao longo do tempo é possível obter uma segmentação dos dados ao se aplicar uma transformação para o domínio da frequência, obtendo-se o espectro de frequências. Essa segmentação normalmente é conhecida como faixas de ondas cerebrais, a qual relaciona faixas de frequências de sinais cerebrais a determinados estados do Cérebro, como alerta e sono, assim como, também possui relação com a idade do indivíduo (BROMFIELD; CAVAZOS; SIRVEN, 2006). As faixas de frequências normalmente utilizadas são delta, theta, alfa, beta e gama (SIULY; LI; ZHANG, 2016), as quais estão, juntamente com os seus símbolos em letras gregas, mostradas na Tabela 1:

Tabela 1 – Típicas ondas cerebrais com suas correspondentes faixas de frequência.

Símbolo	Frequência (Hz)
δ	0,5–4
θ	4–8
α	8–13
β	13–30
γ	>30

Fonte: (SIULY; LI; ZHANG, 2016).

Figura 5 – Sistema 10-20 com nomenclatura alterada. Os pontos com nomes alterados são T7, T8, P7 e P8, os quais se encontram em destaque.



Fonte: Adaptado de (SHARBROUGH *et al.*, 1991).

Segundo (SIULY; LI; ZHANG, 2016) as ondas cerebrais descritas na Tabela 1 em geral têm amplitude menor conforme maior for a sua frequência, além de se relacionarem com os estados cerebrais referentes a atividades e características humanas, tal como: as ondas delta possuem relação com o sono e doenças mentais, as ondas theta se relacionam a emoções negativas como estresse, assim como, a estados mais calmos como meditação, já as ondas alfas se relacionam com atividade mental intensa e com o estado de estar de olhos fechados. As ondas betas têm relação com atividades que exigem foco, como estudo, e por fim as ondas gama com atividades mentais variadas e com movimentos musculares.

A importância das ondas cerebrais para o estudo da epilepsia é evidenciado por (SHORVON *et al.*, 2013) que relaciona, por exemplo, a ocorrência de epilepsias parciais como uma perda de sincronia entre as ondas cerebrais e uma gradual diminuição nas suas atividades, tendo a alteração de ondas específicas conforme a região cerebral. Já em epilepsias generalizadas o autor relata que a forma de tais eventos é normalmente caracterizada por mudanças abruptas no formato das ondas cerebrais, com picos de sinais, tendo ataques epiléticos tônico-clônicos relação com a amplitude das ondas alfa. Assim se evidencia a importância do caráter espectral das ondas obtidas por EEG, podendo revelar características mais dificilmente observadas no domínio do tempo.

2.3 EPILEPSIA E SEUS MÉTODOS USUAIS DE PREDIÇÃO

A epilepsia é uma doença cerebral que possui inúmeras causas, variando de herança genética e infecções a traumas cerebrais e tumores, assim como, diversos tipos de classificações, os quais se relacionam às áreas do Cérebro afetadas (SHORVON *et al.*, 2013). As classificações de crises epiléticas conforme os tipos de sintomas observados podem ser centralizadas nos seguintes grupos: parcial e generalizada (ALBUQUERQUE; CENDES, 2011). Segundo (PANAYIOTOPOULOS, 2005), nas crises epiléticas parciais os sintomas observados podem ser alguns distúrbios sensoriais que podem causar alteração do estado mental, assim como, tremores e contrações musculares involuntárias em partes do corpo, sempre afetando apenas algumas partes do Cérebro, como por exemplo, quando um indivíduo epilético sente alucinações auditivas devido ao evento ocorrer na área auditiva do lobo temporal (PERVEN; SO, 2015). Já nas crises generalizadas o Cérebro é afetado de forma global, envolvendo ambos hemisférios do Cérebro, podendo causar contrações musculares involuntárias generalizadas – a convulsão, sendo essa a classificação que contém um tipo grave de manifestação de convulsões, chamada de tônico-clônica, na qual o indivíduo experimenta um enrijecimento dos músculos ao longo do corpo, normalmente causando a sua queda, e em sequência espasmos causando movimentos involuntários rápidos (PANAYIOTOPOULOS, 2005) (SHORVON *et al.*, 2013).

Embora a ocorrência de eventos epiléticos possa às vezes parecer um evento que seja somente subitamente desencadeado, existem evidências da existência de um estado pré-epilético com relação direta com os ataques epiléticos, chamado de estado pré-ictal, no qual pode haver uma série de alterações das ondas cerebrais, por vezes percebidas subjetivamente pelos indivíduos epiléticos, que aos poucos levam à convulsão ou demais eventos epiléticos, sem haver um período de duração definido, podendo ocorrer diversas horas antes de um ataque (COOK *et al.*, 2013) (ALLAKA *et al.*, 2015) (SHORVON *et al.*, 2013). Nesse estado de iminência antecipada de um evento epilético alguns indivíduos reportam sensações classificadas como auras, que, assim como, durante a ocorrência de eventos epiléticos (estado ictal) parciais, podem causar alterações sensoriais específicas de uma região cerebral como alucinações visuais, auditivas, olfatórias, gustativas ou até mesmo sensações parecidas como a de um leve choque elétrico (PERVEN; SO, 2015).

Dada a discussão sobre a manifestação de eventos pré-ictais e auras, foram desenvolvidos estudos tentando prever a ocorrência de eventos epiléticos. Sendo a natureza dos sintomas variados conforme a região do Cérebro afetada, diferentes abordagens foram feitas de forma a se caracterizar a iminência (adjacente ao ataque epilético ou antecipada) de um evento epilético. As formas de detecção avaliadas foram somente aquelas que possuíssem caráter autônomo, ou seja, sem a supervisão de um médico ou pessoa capaz de interpretar os sinais fisiológicos ou cerebrais apresentados por pessoas que possuam epilepsia.

Segundo o estudo de JORY *et al.* (2016,p. 1), o qual avaliou métodos baseados em "níveis de oxigênio cerebral, alteração de movimentos, mudanças de frequência cardíaca, atividade elétrica em músculos e mudanças na resistência galvânica da pele", excluindo EEG de escalpo por considerar este como não sendo prático no uso cotidiano, constatou que os aparelhos voltados ao monitoramento de movimentos (sensor de pressão, acelerômetro e monitoramento por vídeo) e sinais fisiológicos (frequência cardíaca, resistência galvânica da pele, eletromiografia e sensor infravermelho de oxigenação de hemoglobina) apesar de apresentarem *specificities* (taxa de verdadeiros negativos) consideráveis, possuem *sensitivities* (taxa de verdadeiros positivos) significativamente baixas, o que pode ser muito indesejável para uso em períodos de tempo que não sejam curtos, ou ainda apresentaram variação desses parâmetros entre pacientes (podendo indicar baixa capacidade de generalização).

Avaliando os métodos que utilizaram de redes neurais para predição antecipada de eventos epiléticos, ou na sua iminência, foi avaliado primeiramente o trabalho de (GUPTA; SINGH; KARLEKAR, 2018). Nesse artigo, com o intuito de classificar sinais de EEG entre os estados pré-ictal, inter-ictal (entre eventos epiléticos) e ictal, foi utilizada a abordagem de segregar o sinal conforme as ondas cerebrais delta, theta, alfa, beta e gama. Foram extraídas características utilizando um expoente chamado Hurst para determinar o grau de autocorrelação de um sinal e sua tendência de mudança. Em seguida a utilização de Modelos Auto-Regressivos de Médias Móveis ou *Autoregressive Moving Average* (ARMA) teve o intuito de obter novamente uma autocorrelação com médias móveis e comparação com sinais passados para tentar caracterizar o comportamento atual do sinal e identificar tendências. Por fim foi aplicado um classificador binário de Máquinas de Vetores de Suporte ou *Support Vector Machine* (SVM) para separar os dados em pré-ictal, inter-ictal e ictal. Como resultado foi constatado que os eventos epiléticos têm maior probabilidade de serem detectados nas faixas de ondas cerebrais delta e theta, o que é um resultado que demonstra a relevância de se considerar a utilização de características no domínio da frequência para melhor caracterização dos dados envolvidos no processo analisado. A *sensitivity* obtida foi em torno de 98%, mas os autores informaram que a base de dados utilizada era de tamanho limitado e que tal método empregado carecia de validação em conjuntos de testes maiores.

Outro método inteligente de detecção de eventos epiléticos foi proposto por (AMMAR; SENOUCI, 2016). Nesse trabalho foi abordada a utilização de um único canal de leitura de EEG para análise de eventos epiléticos com inteligência artificial, e foi utilizado como base de dados a mesma base utilizada no presente trabalho, elucidada por (GOLDBERGER *et al.*, 2000). Primeiramente foram escolhidos os dados somente dos pacientes identificados por "chb 03", "chb 08" e "chb 13", utilizando-se somente o canal FT10-T8. Então foi filtrado o sinal para a faixa compreendida entre 0,5 e 30 Hz, considerando que a ocorrência de epilepsias ocorre nessa faixa de frequências. Feito isso foi aplicada a

transformada de Daubechie para separação dos sinais em faixas de frequências próximas das faixas em que se dividem as ondas cerebrais, tal qual feito por (GUPTA; SINGH; KARLEKAR, 2018) através de uma abordagem diferente. Então se utilizou de 6 diferentes métodos de extração de características: no domínio do tempo se extraiu a média do sinal, variância, desvio padrão, assimetria e curtose. Já no domínio da frequência se extraiu a frequência média e frequência de pico. Por fim se classificou o sinal entre epilético e não epilético utilizando o algoritmo Máquina de Aprendizagem Extrema ou *Extreme Learning Machine* (ELM) de forma a se obter uma aprendizagem rápida para um único canal. O resultado obtido foi uma taxa de acerto de cerca de 95%. Os autores apontaram que a aplicação dessa mesma técnica para diversos canais pode ser uma abordagem com chances de melhorar ainda mais a taxa de acerto, ressaltando que o classificador ELM de fato tornou a classificação rápida e que o uso reduzido de canais (no caso o único utilizado) foi bem sucedido.

Agora no âmbito de estudos realizados com enfoque específico na predição antecipada de eventos epiléticos, o trabalho de (LARMUSEAU; DAMBRE, 2016) utilizou dados de Encefalografia Intracraniana ou *Intracranial Electroencephalography* (iEEG) de cães para treinar e validar uma Rede Neural Recorrente ou *Recurrent Neural Network* (RNN). A metodologia utilizada foi de remover sinais de baixa (0,1 Hz) e alta (180 Hz) frequência, dividir os dados em janelas de 30 segundos, extrair características do domínio da frequência com Transformada Discreta de Fourier ou *Discrete Fourier Transform* (DFT) e então segmentar esses dados entre oito categorias de frequências, incluindo as faixas de frequências de ondas cerebrais também analisadas por (GUPTA; SINGH; KARLEKAR, 2018) e (AMMAR; SENOUCI, 2016). A partir disso foram extraídas características para cada um dos oito conjuntos de dados das componentes de Fourier, utilizando o logaritmo da média do módulo. Também se obteve o desvio das médias temporais para cada intervalo de 30 segundos.

No tocante a modelos de ANN, (LARMUSEAU; DAMBRE, 2016) utilizaram três modelos com abordagens de regressão logística, entropia cruzada e de RNNs. O modelo que obteve melhores resultados dentre os três foi o de RNNs. Nesse modelo se utilizou a topologia chamada de Unidade Recorrente de Porta ou *Gated Recurrent Unit* (GRU), a qual é uma versão mais simples e rápida da topologia de RNNs Longa Memória de Curto Prazo ou *Long Short-Term Memory* (LSTM), sendo essa abordagem utilizada devido aos dados se tratarem de sinais com longos períodos de duração do ponto de vista do número de amostras, lembrando que cada dado pontual de características foi obtido a partir de janelas de 30 segundos. A RNN com GRU utilizou somente uma camada e 32 neurônios ocultos para cada característica extraída, com aplicação de regularização L2 para estabilização dos pesos dos neurônios da camada de saída (camada *readout*) e aplicação de desligamento (*dropout*) de neurônios para melhoria de desempenho da rede.

O resultado obtido no trabalho de (LARMUSEAU; DAMBRE, 2016) para a métrica de desempenho de Área Sobre a Curva Característica de Operação do Receptor ou *Area under Receiver Operating Characteristic* (AUROC), que mede quão boa é a performance e equilíbrio entre *sensitivity* e *specificities*, foi de 0,902 na média geral e 1 nos dados de treinamento, indicando sobre-ajuste (*overfitting*) dos dados, o que no entanto foi apontado pelos autores como uma característica de certa forma positiva quando o sobre-ajuste ocorre apenas em uma pequena porção dos dados. Foi concluído que a abordagem usada resultou em predição com percentuais acima de um limiar de somente “chance” de ocorrer uma epilepsia, porém tendo um alto número de falsos positivos e sobre-ajuste dos dados, não alcançando um nível de relevância suficientemente expressivo para uso clínico, conforme análise dos autores.

Utilizando-se também de RNNs e topologia LSTM, (DADGAR-KIANI; ALKAN; SHAMELI, 2016) utilizaram a mesma base de dados que (LARMUSEAU; DAMBRE, 2016), com dados de iEEG de cães e humanos, para predizer a ocorrência de ataques epiléticos e comparar os resultados com a utilização de regressão logística e SVM. Os autores dividiram as gravações de humanos em janelas de 1 minuto, obtiveram a representação em frequência para 16 canais de EEG utilizando Transformada Rápida de Fourier ou *Fast Fourier Transform* (FFT), obtendo, assim como em trabalhos anteriormente analisados, a segregação dos sinais em seis faixas de frequências de ondas cerebrais, sendo elas delta, theta, alfa, beta e gama. Em cada uma dessas bandas, para cada um dos 16 canais, se extraiu a característica de energia espectral e então se usou a RNN com topologia LSTM, utilizando uma célula LSTM para cada janela de dados, totalizando 10 para cada gravação de 10 minutos. Essa RNN foi então treinada para classificar os dados entre inter-ictal e pré-ictal.

Os resultados obtidos por (DADGAR-KIANI; ALKAN; SHAMELI, 2016) mostraram que a RNN com LSTM obteve a maior AUROC com valor de 0,94, apesar dos métodos de regressão logística e SVM terem obtido valores acima de 0,9 também. Já o método de SVM obteve a maior *specificity*. Os autores apontam que a energia espectral é a medida mais importante para caracterizar sinais de EEG e que a performance do classificador poderia ser melhorada de várias maneiras, como com a utilização de mais características, tais quais transformadas discretas de *wavelets*, assim como características temporais. Também sugeriram a utilização de Redes Neurais Convolucionais ou *Convolutional Neural Networks* (CNNs) para automaticamente extrair características mais significativas do espectrograma obtido inicialmente, o que é uma sugestão interessante dada a variedade de características que tiveram de ser obtidas manualmente nos trabalhos citados anteriormente. Além disso os autores ressaltaram que, dado ao fato de os dados terem muito mais estados inter-ictal do que pré-ictal, ou seja, representarem uma base desbalanceada, foi tentado aumentar a *specificity* em detrimento do número de falsos positivos, de forma a compensar essa característica dos dados.

Tendo em vista os trabalhos desenvolvidos tentando abordar os sinais fisiológicos cerebrais com redes neurais, é possível perceber que há alguns aspectos apontados pelos autores que podem vir a serem úteis na presente pesquisa. Dentre esses pontos há a filtragem dos sinais provenientes da base de dados, visto que as ondas cerebrais de interesse se encontram no espectro aproximado de cerca de 0,5 a pouco mais de 30 Hz, conforme a Tabela 1, visando a remoção de sinais que possam atrapalhar o treinamento da rede e impactar na caracterização dos períodos ictal e pré-ictal. Já no escopo da seleção de características é possível perceber que foi utilizado mais de uma vez a transformação dos sinais para o domínio da frequência e então segregados entre os espectros das ondas cerebrais. Posteriormente a isso, o trabalho de (GUPTA; SINGH; KARLEKAR, 2018) identificou dois espectros de onda como tendo maior significância na classificação dos estados epiléticos, sendo esses espectros o delta e o theta. Essa informação, caso identificada como verdadeira na presente pesquisa, pode vir a ajudar na diminuição de vetores de dados utilizados, diminuindo a carga de trabalho e por consequência a complexidade da rede.

2.4 REDES NEURAIAS ARTIFICIAIS

ANNs são um tipo de algoritmo no qual informações de entrada são transmitidas e moduladas até chegarem a nódulos ou neurônios artificiais, os quais aplicam funções matemáticas no sinal modulado, gerando uma saída. O conjunto transmissão-neurônio é conhecido como “camada”. Uma rede neural pode ter diversas entradas, camadas e neurônios, interconectando-se de forma a fazer que o sinal gerado por um neurônio de uma camada passe por todos neurônios da camada seguinte, podendo ter como um dos objetivos finais a classificação dos dados de entrada entre diferentes categorias ou grupos. Essa arquitetura de algoritmo com transmissão de dados entre nodos é baseada de forma abstrata na anatomia dos neurônios e nas sinapses cerebrais (HAYKIN, 2009).

Uma característica das redes neurais é a capacidade de “aprendizagem”, a qual deriva de métodos de atualização dos pesos assinalados às conexões entre os neurônios, ato conhecido como treinamento de uma rede neural. Através de treinamentos é possível gerar uma rede neural, ou um algoritmo matemático, capaz de classificar ou generalizar dados de entrada, gerando saídas relevantes conforme os dados de treinamento aplicados, buscando diminuir o erro entre a saída atual e a desejada conforme os dados de treinamento (no caso de uma ANN com treinamento supervisionado) (GUYON *et al.*, 2006). Dentre esses métodos um dos mais comuns e utilizados é a retropropagação, ou *backpropagation*, o qual calcula em cada determinado momento do treinamento o erro entre a saída atual e a desejada, e retropropaga para as camadas anteriores esse erro de forma a atualizar os pesos das interconexões entre neurônios, buscando diminuir o erro para a próxima época de treinamento (HAYKIN, 2009).

O treinamento de uma rede trabalha com a topologia utilizada para a ANN, podendo essa ser de diversos tipos, sendo cada um mais apropriado para solução de problemas específicos (CHELLAPPA *et al.*, 2013), sendo a topologia um fator crucial para a determinação de que tipo de sistema é mais eficientemente apreendido (CHELLAPPA *et al.*, 2013). Por exemplo, há topologias que possuem a capacidade de armazenar dados durante o treinamento em seus neurônios, o que gera bons resultados para dados de natureza temporal, como sinais de áudio ou sinais de leituras fisiológicas como o EEG (CHELLAPPA *et al.*, 2013).

Além da topologia, a extração de características do sinal é uma importante técnica para permitir às ANNs assimilar matematicamente padrões que caracterizem determinado sinal (BISHOP, 1995), podendo haver análise em diferentes domínios como o da frequência, assim como, a determinação de características matemáticas como valor médio, desvio padrão, curtose, energia, dentre outros.

Dadas as peculiaridades presentes em redes neurais, se faz necessário revisar seus modelos e métodos envolvidos de forma a melhor compreender as abordagens possíveis para detecção de estados pré-ictais e conseqüente predição de ataques epiléticos a partir dos sinais de EEG.

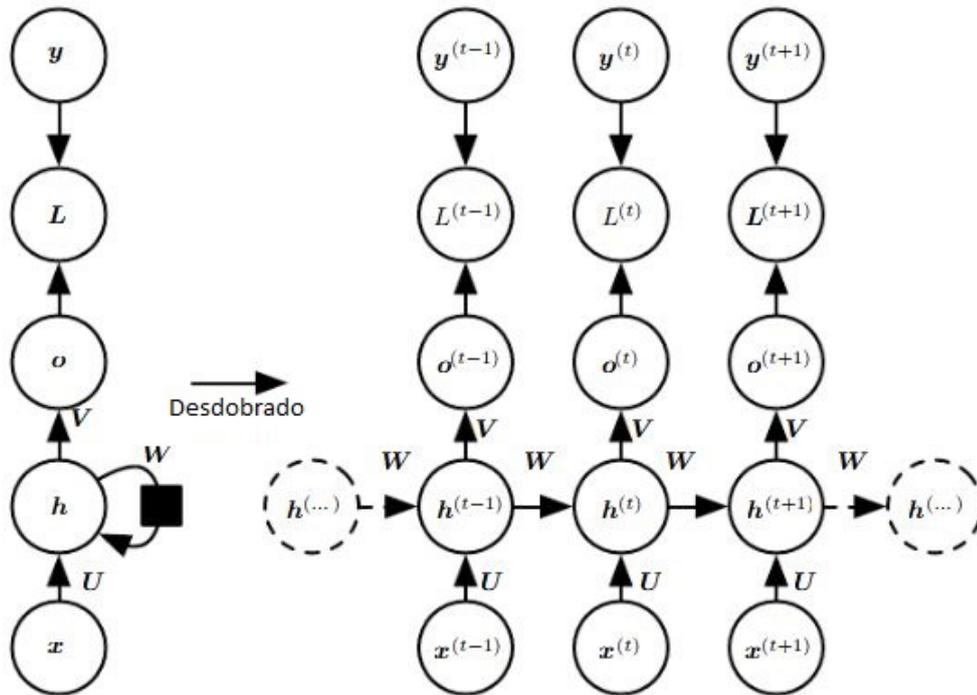
2.4.1 Redes Neurais Recorrentes

Com o emprego cada vez mais frequente de redes neurais para solução de diversos tipos de problemas, foi identificado que Redes Neurais Multicamadas de Alimentação Direta ou *Multilayer Feed Forward Neural Networks* (MLFFNs) não conseguem resolver satisfatoriamente problemas que envolvam grandes dependências temporais do sinal de entrada (SUNDERMEYER; NEY; SCHLÜTER, 2015), assim como ocorre, por exemplo, em sinais de voz envolvendo frases, no qual por vezes a palavra ou dado atual tem correlação direta a uma palavra que foi fornecida como entrada vários momentos antes no fluxo de entrada de dados da rede. Portanto, se identificou que uma topologia que apresenta a capacidade de lidar com esse tipo de dependência são as RNNs.

As RNNs, em contraste com as MLFFNs, conseguem armazenar informações referentes a dados analisados em iterações anteriores devido ao fato de possuírem uma estrutura cíclica de realimentação de dados (GOODFELLOW; BENGIO; COURVILLE, 2016). Essa estrutura garante um funcionamento a cada camada recorrente da rede tal como uma série muito extensa de camadas neurais (GOODFELLOW; BENGIO; COURVILLE, 2016), como visto na Figura 6.

Na Figura 6 há um neurônio de entrada chamado de "x", uma unidade oculta, que realiza o processamento da rede recorrente, denotada por "h", uma matriz de pesos "W" para parametrização, pesos "U" e "V" de interconexão entre neurônios, um neurônio de saída "o", a saída desejada (ou alvo), denotada por "y", e o erro "L", o qual indica o

Figura 6 – RNN e sua equivalência de funcionamento como muitas camadas neurais.



Fonte: Adaptado de (GOODFELLOW; BENGIO; COURVILLE, 2016).

quão distante a saída atual "o" está da saída desejada "y". Esses agentes possuem uma dependência com o instante de tempo atual pois seus valores serão calculados com base no estado atual e nos estados que transcorreram anteriormente. Como já dito na comparação com MLFFNs, essa estrutura com dependência do estado atual e dos anteriores pode ser desdobrada em uma MLFFN com interconexões, onde cada instante de tempo seria também desdobrado em uma entrada distinta. Considerando ainda a existência de valores de limiar, ou *bias*, denotados por "b", e a aplicação de uma função de ativação "f", o estado oculto desse arranjo pode ser equacionado conforme se vê na Equação (1).

$$h^{(t)} = f(Ux^{(t)} + Wh^{(t-1)} + b) \quad (1)$$

Esse funcionamento demonstra como a estrutura das RNNs pode ter uma “memória” dos eventos anteriores.

A estrutura de realimentação das RNNs pode variar em seu funcionamento, tendo como pontos centrais de variação, por exemplo, as unidades ocultas e os neurônios de saída. Por exemplo, na Figura 6 vê-se uma realimentação somente entre unidades ocultas, mas poderia-se ainda ter interconexões entre o neurônio de saída e a unidade oculta, de forma a considerar a saída gerada em relação aos dados de um instante para os demais seguintes, através da utilização desses dados na atualização dos pesos envolvidos na unidade oculta.

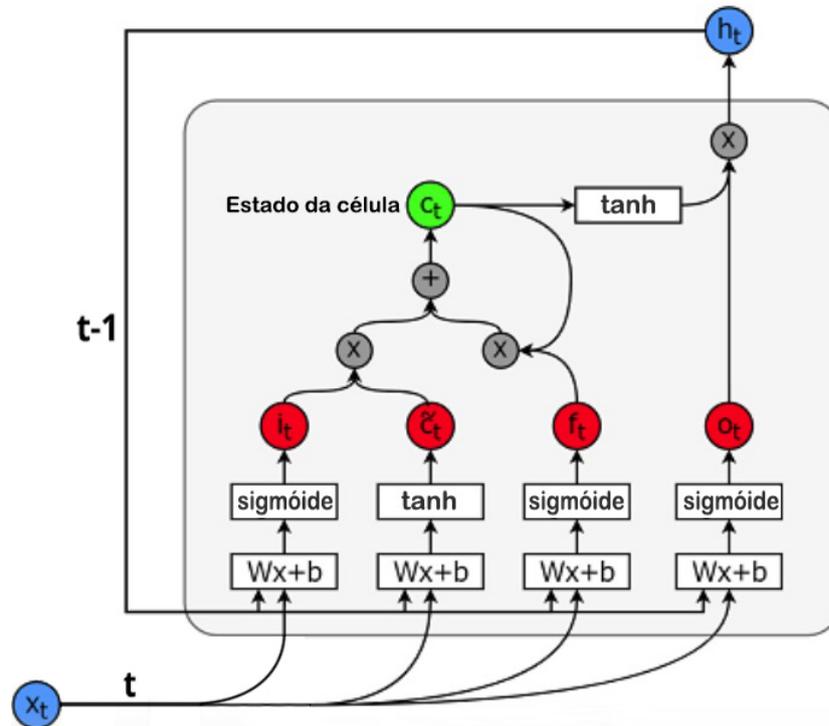
Apesar de capacidade apresentada de considerar entradas em iterações anteriores, tal qual possuísse uma memória, foi identificado por (BENGIO; SIMARD; FRASCONI, 1994) um problema inerente às redes recorrentes padrões referente ao aprendizado. (BENGIO; SIMARD; FRASCONI, 1994) demonstram que conforme ocorre o processo de aprendizagem de uma rede recorrente, surge o problema do gradiente de desaparecimento/gradiente evanescente (*vanishing gradient*) ou de explosão (*exploding gradient*), no qual os termos de memória longa, referentes a entradas anteriores distantes da entrada atual, são minimizados a ponto de terem pouca influência no aprendizado, perdendo a capacidade de memória, ou crescem de forma a se tornarem muito maiores que a entrada atual, dando um peso indesejado à memória de longo prazo da rede em detrimento da entrada atual. Para tanto se concluiu que há um problema no processo de aprendizado de RNNs padrões, se fazendo necessário o uso de variações ou especializações das mesmas para apropriada consideração da memória de longo prazo. Para tanto será analisado algumas soluções a esse problema.

2.4.2 Redes Recorrentes do tipo LSTM

Conforme analisado, as RNNs possuem um problema de aprendizado conforme as iterações do algoritmo de aprendizagem ocorrem. Uma das soluções propostas são as variações de RNNs chamadas de Longa Memória de Curto Prazo ou *Long Short-Term Memory* (LSTM).

A rede recorrente LSTM foi primeiramente introduzida por (HOCHREITER; SCHMIDHUBER, 1997) e aprimorada por (GERS; SCHMIDHUBER, 2000) com a adição das chamadas portas de esquecimento, resultando na topologia de RNNs apresentada na Figura 7:

Figura 7 – Arquitetura típica de uma rede recorrente do tipo LSTM.



Fonte: Adaptado livremente de (GANEGEDARA, 2018).

A diferenciação de uma RNN LSTM para uma RNN padrão se dá na introdução de uma célula de memória, localizada entre a entrada "x" e a unidade oculta "h", introduzindo portas que gerenciam o fluxo de dados conforme o interesse em mantê-los para a análise que estiver sendo executada pela rede.

Observando a topologia da LSTM representada na Figura 7, é possível perceber que existem quatro portas que influenciam o resultado enviado para a unidade oculta através do uso de funções de ativação (neste exemplo, as funções de ativação do tipo sigmóide e tangente hiperbólica) e de adição e multiplicação elemento a elemento dos dados obtidos. Os subscritos 't' denotam que os estados tratados são referentes à entrada atual de dados, e não a dados de instantes anteriores. A funcionalidade de cada porta é descrita separadamente a seguir para melhor compreensão, e juntamente de cada descrição há o equacionamento matemático, utilizando a notação de instante de tempo entre parênteses ao invés de somente subscrito e utilizando a mesma notação de pesos da topologia de rede representada pela Figura 7.

Estado oculto ($h_{(t)}$): o estado oculto é a saída da rede LSTM, onde se obtém, no caso do presente trabalho, os dados preliminares de previsão que informa se a sequência de dados de entrada indica que irá ocorrer um ataque epilético. Conforme a Equação (2), através da multiplicação por uma matriz de pesos (referir à Figura 6) para parametrização, se obtém a saída final. É importante notar que na Figura 7 esse estado é realimentado na entrada

da célula de memória, configurando um dos tipos de topologia de RNN anteriormente discutidos.

$$h_{(t)} = o_{(t)} \odot \tanh(c_{(t)}) \quad (2)$$

Estado da célula ($C_{(t)}$): nessa unidade são armazenados valores de interesse que passaram pela rede, valores que foram filtrados conforme a relevância dada a partir do processo de treinamento. É nesta unidade que ocorre o processo de armazenamento final da célula de memória, que interage com o estado oculto conforme o decorrer do fluxo de dados de entrada, como explicitado na Equação (3):

$$c_{(t)} = (i_{(t)} \odot \tilde{c}_{(t)}) \oplus (f_{(t)} \odot c_{(t-1)}) \quad (3)$$

Porta de modulação/bloqueio da entrada ou nodo de entrada (\tilde{c}_t): criação do vetor de dados candidatos a serem considerados na determinação do estado atual. A Equação (4) representa o equacionamento da criação do vetor de dados candidatos.

$$\tilde{c}_{(t)} = \tanh(W_c(x_{(t)}, h_{(t-1)}) + b_c) \quad (4)$$

Porta de entrada ($i_{(t)}$): seleção de dados de entrada para avaliação no estado atual. Após a seleção dos dados candidatos a serem considerados no estado atual pelo nodo de entrada, conforme a Equação (5), a porta de entrada calcula os pesos a serem multiplicados termo a termo, variando os pesos de 0 a 1 através de uma função de ativação sigmoideal, de forma que o valor 1 representa que o dado em questão deve ser completamente considerado no estado atual.

$$i_{(t)} = \sigma(W_i(x_{(t)}, h_{(t-1)}) + b_i) \quad (5)$$

Porta de esquecimento ($f_{(t)}$): através da análise da entrada atual, estado oculto e estado/memória anterior da célula, se decidem quais dados não são relevantes na análise do estado atual mesmo que sejam relevantes posteriormente, sendo que um valor 1 da função sigmoideal dessa porta representa que o dado em questão deva ser completamente esquecido. O equacionamento para decisão da irrelevância dos dados é visto na Equação (6):

$$f_{(t)} = \sigma(W_f(x_{(t)}, h_{(t-1)}) + b_f) \quad (6)$$

Porta de saída ($o_{(t)}$): essa porta faz a seleção do quanto da análise atual deve fluir para o estado oculto, tendo equacionamento exibido na Equação (7). Caso a análise da rede decida que a memória de curto prazo, proveniente do estado da célula e da entrada

atual, seja o único dado relevante para análise atual, essa porta não permite a passagem do fluxo de dados, mantendo a análise feita na análise atual internamente, ou seja, somente na célula de memória, e não passando a mesma ao estado oculto.

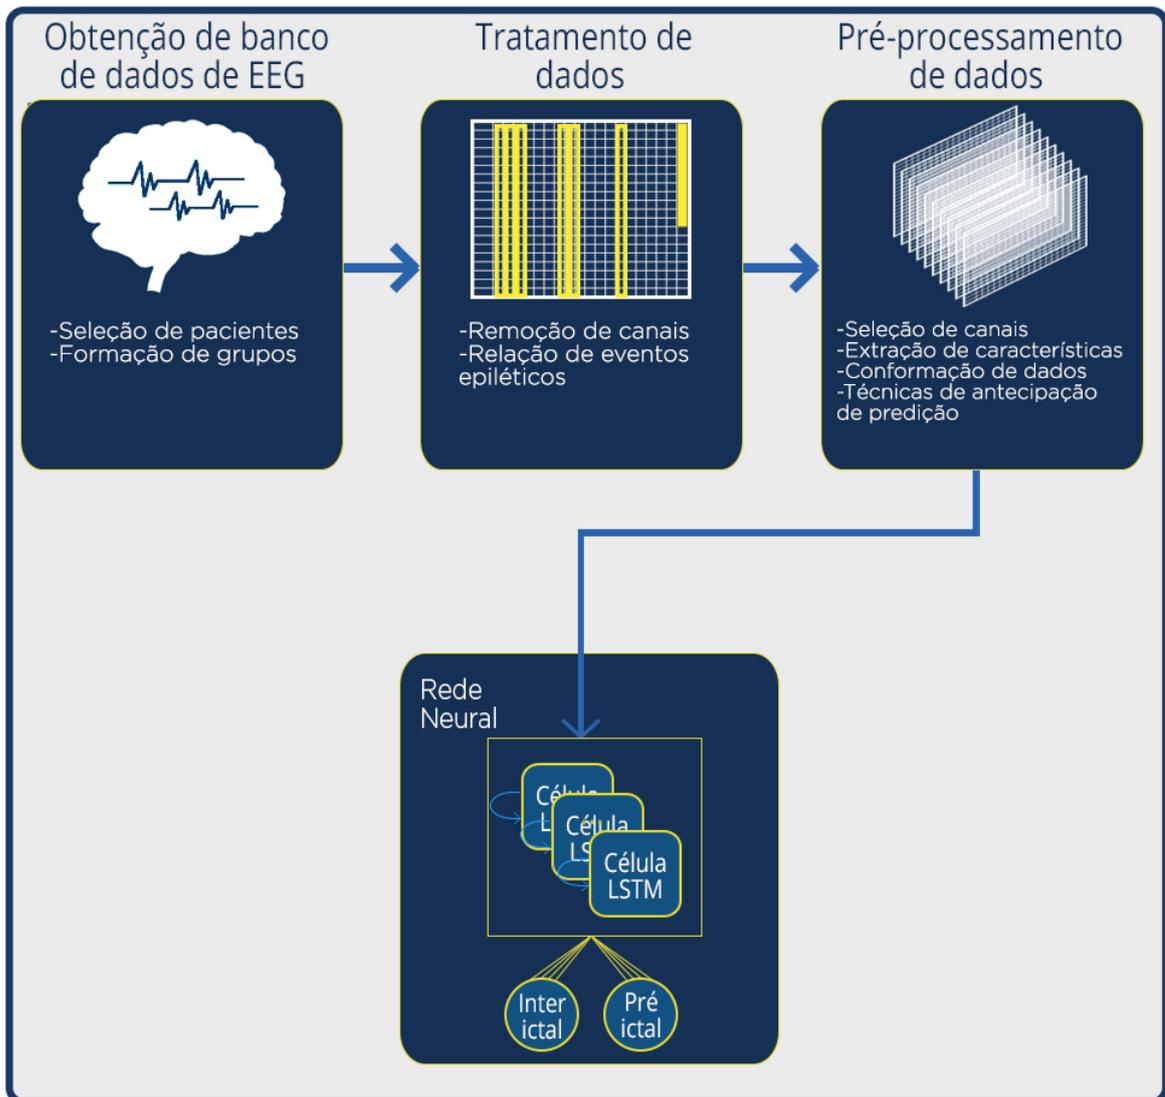
$$o_t = \sigma(W_o(x_{(t)}, h_{(t-1)}) + b_o) \quad (7)$$

Um detalhe de implementação a ser notado é a realimentação do estado da célula que é multiplicada termo a termo com a porta de esquecimento. Nessa realimentação há um atraso de somente uma unidade de tempo (HOCHREITER; SCHMIDHUBER, 1997), representada implicitamente na Figura 7. Portanto o processamento de dados com memória de curto prazo tem influência direta do estado imediatamente anterior.

3 METODOLOGIA EXPERIMENTAL

A partir do objetivo de desenvolver uma RNN para classificação de segmentos de sinais pré-ictais de EEG, a estrutura da rede e a extração de características dos dados tem por finalidade obter os padrões matemáticos mais significativos dos sinais de entrada que resultem em taxas de acerto adequadas para uma correta classificação. A proposta para viabilizar o correspondente objetivo deste trabalho é apresentada no formato de um diagrama de blocos, apresentado na Figura 8:

Figura 8 – Diagrama de blocos da estrutura principal do trabalho.



A solução consiste em selecionar gravações de EEG de pacientes de uma base de dados (PHYSIONET, 2018a) e converter esses dados para o formato Valores Separados por Vírgula ou *Comma Separated Values* (CSV) para mais fácil manipulação e visualização dos dados. Uma vez organizados os dados de EEG, são removidos os sinais indesejados e adicionadas informações referentes à ocorrência de ataques epiléticos. Após é realizado o pré-processamento dos dados visando conformá-los e transformá-los de forma a encontrar

padrões com correlação significativa com o estado pré-ictal. Por fim esses dados são pré-processados para treinar a ANN e gerar um modelo que seja capaz de classificar estados pré-ictais em sinais de EEG. Mais de uma abordagem é utilizada no pré-processamento de dados, buscando aumentar o tempo de antecedência com que os ataques epiléticos são detectados pela ANN.

A ANN a ser desenvolvida é do tipo Recorrente LSTM, a qual deve então ser constituída de células LSTM de entrada que analisarão o fluxo de sequências de canais de entrada de EEG considerando as características extraídas a partir dos dados, fazendo com que a dimensão de cada entrada de dados seja o produto de N canais (colunas do arquivo no formato CSV) por M características. Os módulos LSTM então disponibilizam uma saída que classifica a sequência atual entre pré-ictal ou inter-ictal, ou seja, se é predito que a sequência atual irá culminar em um estado epilético ou não. Nos capítulos posteriores cada um dos principais blocos serão abordados.

De forma a prover toda estruturação, treinamento e análise de redes neurais e dos dados utilizados pelas mesmas, foi utilizada a biblioteca de código aberto TensorFlow (TENSORFLOW, 2018), devido ao elevado nível de abstração e abrangência de documentação e de usuários. Juntamente ao Tensorflow, é utilizada a biblioteca Keras (KERAS, 2018), a qual estende, dentre outros sistemas, o Tensorflow, de forma a facilitar o desenvolvimento e mudanças nas redes neurais desenvolvidas. Portanto, a menos que explicitado, os procedimentos de manipulação de dados e o desenvolvimento de estruturas de ANN no presente trabalho envolvem o uso das ferramentas descritas.

3.1 BANCO DE DADOS

De modo a treinar a rede neural desenvolvida no presente trabalho, se faz necessário o uso de dados de EEG de indivíduos epiléticos durante os estados que se deseja classificar, ou seja, nos estados ictal e pré-ictal. Através de uma pesquisa por bases de dados de EEG, foi identificada uma base de dados gratuita (PHYSIONET, 2018a) (GOLDBERGER *et al.*, 2000) obtida por um time de pesquisadores da instituição americana *Massachusetts Institute of Technology* e do hospital *Children's Hospital Boston*, na qual são registrados sinais de EEG de escalpo por dezenas de horas, a partir do monitoramento de pacientes epiléticos pediátricos, totalizando 22 indivíduos. Os dados obtidos são divididos por indivíduos, identificados por números precedidos do prefixo "chb_". Cada caso (dados de um mesmo indivíduo) contém entre 9 e 42 arquivos com a extensão de Formato de Dados Europeu ou (*European Data Format*) (EDF), sendo a maioria desses arquivos constituídos de cerca de uma hora de gravação de sinais de EEG de escalpo do paciente em questão. O monitoramento de dados foi realizado utilizando-se 23, 24 ou 26 canais de sinais de EEG (eletrodos posicionados no escalpo), sendo realizado com posição e nomenclaturas definidas no Sistema Internacional 10-20. Esse monitoramento foi realizado a uma taxa de

amostragem de 256 amostras por segundo com resolução de conversão analógica-digital de 16 bits, sendo as medidas de cada eletrodo apresentadas em microvolts.

A partir do monitoramento por EEG de escalpo de pacientes com epilepsia intratável (PHYSIONET, 2018a), o banco de dados utilizado é constituído de diversos casos de pacientes, alguns apresentando a ocorrência de eventos epiléticos durante o monitoramento e outros não. De forma a se representar a distribuição de eventos epiléticos por casos, é possível ver na Tabela 2 a relação de todos os casos organizados em ordem decrescente de número de arquivos com eventos epiléticos observados.

Tabela 2 – Relação desbalanceada de pacientes dispostos em ordem decrescente de quantidade de arquivos com eventos epiléticos registrados em cada caso. Os pacientes estão agrupados em três categorias genéricas para melhor distinção da densidade de eventos epiléticos.

Quantidade de eventos	Paciente	Nº de arquivos com eventos epiléticos	Nome dos arquivos
>10	chb15	14	06,10,15,17,20,22,28,31,40,46,49,52,54,62
	chb12	13	06,08,09,10,11,23,27,28,29,33,36,38,42
	chb24	12	01,03,04,06,07,09,11,13,14,15,17,21
5<eventos<10	chb13	8	19,21,40,55,58,59,60,62
	chb01	7	19,21,40,55,58,59,60,62
	chb03	7	01,02,03,04,34,35,36
	chb06	7	01,04,09,10,13,18,24
	chb10	7	12,20,27,30,31,38,89
	chb14	7	03,04,06,11,17,18,27
	chb16	6	10,11,14,16,17,18
	chb18	6	29,30,31,32,35,36
	chb20	6	12,13,14,15,16,68
<=5 eventos	chb05	5	06,13,16,17,22
	chb08	5	02,05,11,13,21
	chb21	4	19,20,21,22
	chb02	3	16,16+,19
	chb04	3	05,08,28
	chb07	3	12,13,18
	chb09	3	06,08,19
	chb11	3	82,92,99
	chb17	3	03,04,63
	chb19	3	28,29,30
	chb22	3	20,25,38
	chb23	3	06,08,09

A relação da Tabela 2 não somente dispõe os pacientes em ordem decrescente de número de arquivos com eventos observados no caso em questão, como também os segrega em três grupos conforme a quantidade de eventos epiléticos em um único caso. Analisando o resultado da correspondente divisão é possível constatar a existência de 3 casos com mais de 10 arquivos com eventos epiléticos observados em cada, 9 casos contendo de 6 a 9 arquivos com eventos, e por fim 12 casos com 5 ou menos arquivos com eventos epiléticos registrados. Essa classificação pode se mostrar útil para melhor seleção dos casos a se utilizar no treinamento da rede neural, fazendo um refinamento dos casos de forma a se reduzir o treinamento excessivo com casos onde poucos eventos epiléticos são observados. Outras abordagens também podem avaliar essa classificação de forma diferente, mudando a relevância da classificação para outro aspecto qualitativo, o qual consiste em avaliar o aumento ou diminuição da performance da ANN ao se privilegiar os dados de uma das categorias da classificação.

Os casos, os quais são constituídos de dados de EEG, obtidos pela pesquisa que levou à criação da base de dados (GOLDBERGER *et al.*, 2000), foram organizados e disponibilizados em arquivos com a extensão EDF. De forma a manipular facilmente esses dados, os mesmos foram convertidos para o formato CSV utilizando a ferramenta WFDB (*Waveform Database*) disponibilizada pelo próprio banco de dados (PHYSIONET, 2018a) e disponível em (PHYSIONET, 2018b).

Ao se analisar os dados obtidos, foi identificado que os mesmos diferiam no número de colunas apresentadas, configurando uma base de dados desbalanceada em número de características (nesse caso, canais de EEG), ou seja, nem todos arquivos apresentam a leitura dos mesmos canais. A título de exemplificação, e para melhor análise desse aspecto, é exibido na Tabela 3 a relação de todo primeiro grupo de casos relacionados na Tabela 2, juntamente com seus arquivos e os canais de cada arquivo.

A Tabela 3 evidencia o desbalanceamento de canais e inclusive a existência de arquivos onde não há nenhum canal em comum com os outros arquivos, como ocorre, por exemplo, no arquivo 27 do caso chb12. Entretanto para a grande maioria dos arquivos se identificou um conjunto de canais padrões, os quais aparecem com grande frequência. Esses canais são: FP1-F7, F7-T7, T7-P7, P7-O1, FP1-F3, F3-C3, C3-P3, P3-O1, FZ-CZ, CZ-PZ, FP2-F4, F4-C4, C4-P4, P4-O2, FP2-F8, F8-T8, T8-P8. Portanto no caso em que se deseje balancear de forma artificial essa base de dados (sem o uso de nenhum critério científico), se faz necessário retirar os arquivos que não contenham todos canais denominados aqui como “padrões” e remover as demais colunas indesejadas dos arquivos que contenham os canais padrões.

Considerando que o eficaz aumento da taxa de *specificity* (razão do número de predições verdadeiro negativas pela soma de todas predições verdadeiro negativas e falso negativas) possa ter correlação com trechos de sinais onde não há ocorrência de eventos

Tabela 3 – Relação dos canais para cada arquivo de casos selecionados, evidenciando o desbalanceamento de canais da base de dados.

Paciente	Arquivo(s)	Canais do(s) arquivo(s)
chb15	01	FP1-F7, F7-T7, T7-P7, P7-O1, FP1-F3, F3-C3, C3-P3, P3-O1, FZ-CZ, CZ-PZ, FP2-F4, F4-C4, C4-P4, P4-O2, FP2-F8, F8-T8, T8-P8, P8-O2, FC1-Ref, FC2-Ref, FC5-Ref, FC6-Ref, CP1-Ref, CP2-Ref, CP5-Ref, CP6-Ref
	02-63	FP1-F7, F7-T7, T7-P7, P7-O1, FP1-F3, F3-C3, C3-P3, P3-O1, FZ-CZ, CZ-PZ, PZ-OZ, FP2-F4, F4-C4, C4-P4, P4-O2, FP2-F8, F8-T8, T8-P8, P8-O2, P7-T7, T7-FT9, FT9-FT10, FT10-T8, T8-P8, FC1-Ref, FC2-Ref, FC5-Ref, FC6-Ref, CP1-Ref, CP2-Ref, CP5-Ref, CP6-Ref
	06-24	FP1-F7, F7-T7, T7-P7, P7-O1, FP1-F3, F3-C3, C3-P3, P3-O1, FZ-CZ, CZ-PZ, FP2-F4, F4-C4, C4-P4, P4-O2, FP2-F8, F8-T8, T8-P8, P8-O2, P7-T7, T7-FT9, FT9-FT10, FT10-T8, T8-P8
chb12	27	F7-CS2, T7-CS2, P7-CS2, FP1-CS2, F3-CS2, C3-CS2, P3-CS2, O1-CS2, FZ-CS2, CZ-CS2, PZ-CS2, FP2-CS2, F4-CS2, C4-CS2, P4-CS2, O2-CS2, F8-CS2, T8-CS2, P8-CS2, C2-CS2, C6-CS2, CP2-CS2, CP4-CS2, CP6-CS2
	28-29	F7, T7, P7, FP1, F3, C3, P3, O1, FZ, CZ, PZ, FP2, F4, C4, P4, O2, F8, T8, P8, EKG1-CH, C2, C6, CP2, CP4, CP6
	32-42	FP1-F7, F7-T7, T7-P7, P7-O1, FP1-F3, F3-C3, C3-P3, P3-O1, FZ-CZ, CZ-PZ, FP2-F4, F4-C4, C4-P4, P4-O2, FP2-F8, F8-T8, T8-P8, P8-O2, P7-T7, T7-FT9, FT9-FT10, FT10-T8, T8-P8, LOC-ROC
chb24	01-21	FP1-F7, F7-T7, T7-P7, P7-O1, FP1-F3, F3-C3, C3-P3, P3-O1, FP2-F4, F4-C4, C4-P4, P4-O2, FP2-F8, F8-T8, T8-P8, P8-O2, FZ-CZ, CZ-PZ, P7-T7, T7-FT9, FT9-FT10, FT10-T8, T8-P8

epiléticos, e também considerando que eventualmente o desbalanceamento de dados de uma determinada classe (classes que indicam se está ou não está havendo um ataque epilético) possam eventualmente submeter o treinamento da rede neural a aprender a classificar muito melhor ocorrências de uma só classe, é considerado a segmentação aleatorizada de grupos de treinamento de forma a comparar a melhor performance da ANN de acordo com a densidade de eventos epiléticos apresentada à mesma. Juntamente com o aspecto do número de eventos epiléticos apresentados, há a possibilidade de um paciente ter padrões de atividades cerebrais diferentes dos demais, dado que apresentou no mesmo período de tempo mais eventos epiléticos que outros pacientes, havendo mais frequentemente a ocorrência de distúrbios no funcionamento normal do seu Cérebro. Portanto a estratégia

de randomização possivelmente minimiza que ocorra um viés de seleção dos pacientes utilizados no treinamento.

Tendo em vista a necessidade de validação da relação de performance da rede de acordo com a escolha de dados a serem expostos à mesma, as categorias da Tabela 2 são utilizadas para ser criar grupos de treinamento com distribuições específicas, as quais são apresentadas na Tabela 4:

Tabela 4 – Agrupamento de pacientes de forma aleatorizada para realização de treinamento sem viés de seleção. Grupos enumeram pacientes com diferentes densidades de eventos epiléticos num mesmo período de tempo, evidenciando possíveis diferenças de padrões de atividades cerebrais.

Grupo	Critério de escolha do paciente	Pacientes	Nº de arquivos com eventos epiléticos
1	Todos do grupo com maior número de eventos	chb15	14
		chb12	13
		chb24	12
2	Maior número de eventos de cada grupo	chb15	14
		chb13	8
		chb05	5
3	Aleatorização completa	chb14	7
		chb17	3
		chb19	3
4	Bloco aleatorizado	chb15	14
		chb16	6
		chb08	5

A criação dos grupos da Tabela 4 segue quatro padrões distintos baseando-se nas categorias definidas na Tabela 2. No primeiro grupo são escolhidos todos os pacientes da categoria de maior ocorrência de eventos epiléticos. No segundo grupo são escolhidos os pacientes com maior número de eventos epiléticos dentro de cada uma das três categorias. No terceiro grupo há a aleatorização de três pacientes independente das categorias. Por fim no quarto e último grupo há a aleatorização de um paciente dentro de cada categoria. É possível notar que em cada grupo está presente um perfil de pacientes com densidade de eventos epiléticos distintos, em especial no segundo e quarto grupos, fazendo com que o treinamento abranja diversos cenários.

Para cada paciente da Tabela 4 são utilizados somente os arquivos de EEG que apresentem eventos epiléticos, removendo aqueles que não apresentem nenhum evento. Esse procedimento é escolhido pois cada arquivo de EEG da base de dados utilizada no presente trabalho apresenta uma regularidade de desbalanço no tempo de duração dos eventos epiléticos em relação à duração de períodos inter-ictais, então cada arquivo conserva o padrão observado em toda a base de dados, permitindo uma representatividade coerente.

Juntamente a isso, ao se utilizar somente os arquivos que apresentem eventos epiléticos, é viabilizado que se possa comparar diretamente a densidade de eventos epiléticos avaliada em cada paciente.

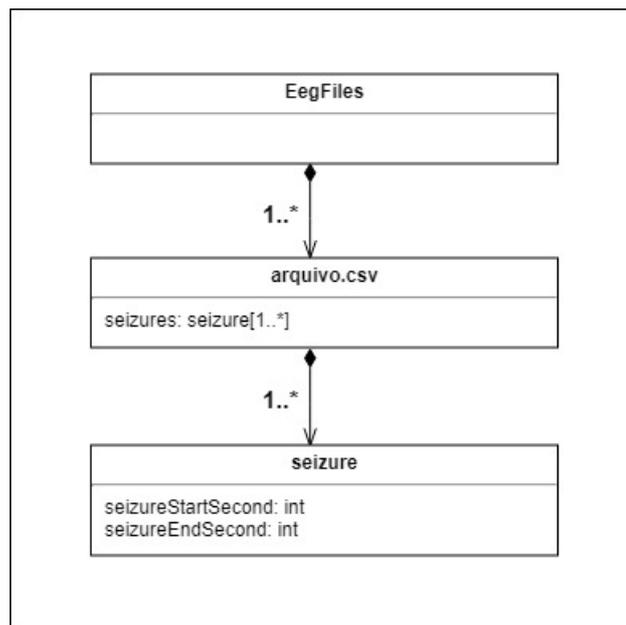
Os grupos de treinamento formados totalizam a utilização de dados de 10 dos 24 pacientes presentes na base de dados, somando o processamento de 104 horas de EEG e eventos epiléticos.

Além dos dados de EEG, foram disponibilizados por (PHYSIONET, 2018a) arquivos com marcações de tempo, ou *timestamps*, de forma a identificar os momentos em que foram detectados ataques epiléticos, sendo as marcações constituídas do momento de início e de término dos eventos, dessa forma sendo possível posteriormente relacionar nos arquivos de EEG as entradas nas quais foi detectado um evento epilético ou a ausência dele.

3.2 TRATAMENTO DE DADOS

De forma a se organizar os dados referentes aos eventos epiléticos, com o intuito de facilitar sua leitura a partir de um algoritmo, decidiu-se relacionar os dados disponibilizados pela base de dados em um arquivo com extensão Notação de Objetos JavaScript ou (*JavaScript Object Notation*, ou resumidamente JSON). Para cada paciente (também referido como caso) foi criado um arquivo JSON com a seguinte estrutura de dados mostrada na Figura 9:

Figura 9 – Diagrama de classes dos arquivos com extensão JSON criados a partir dos dados de marcação de tempo disponibilizados pela base de dados.

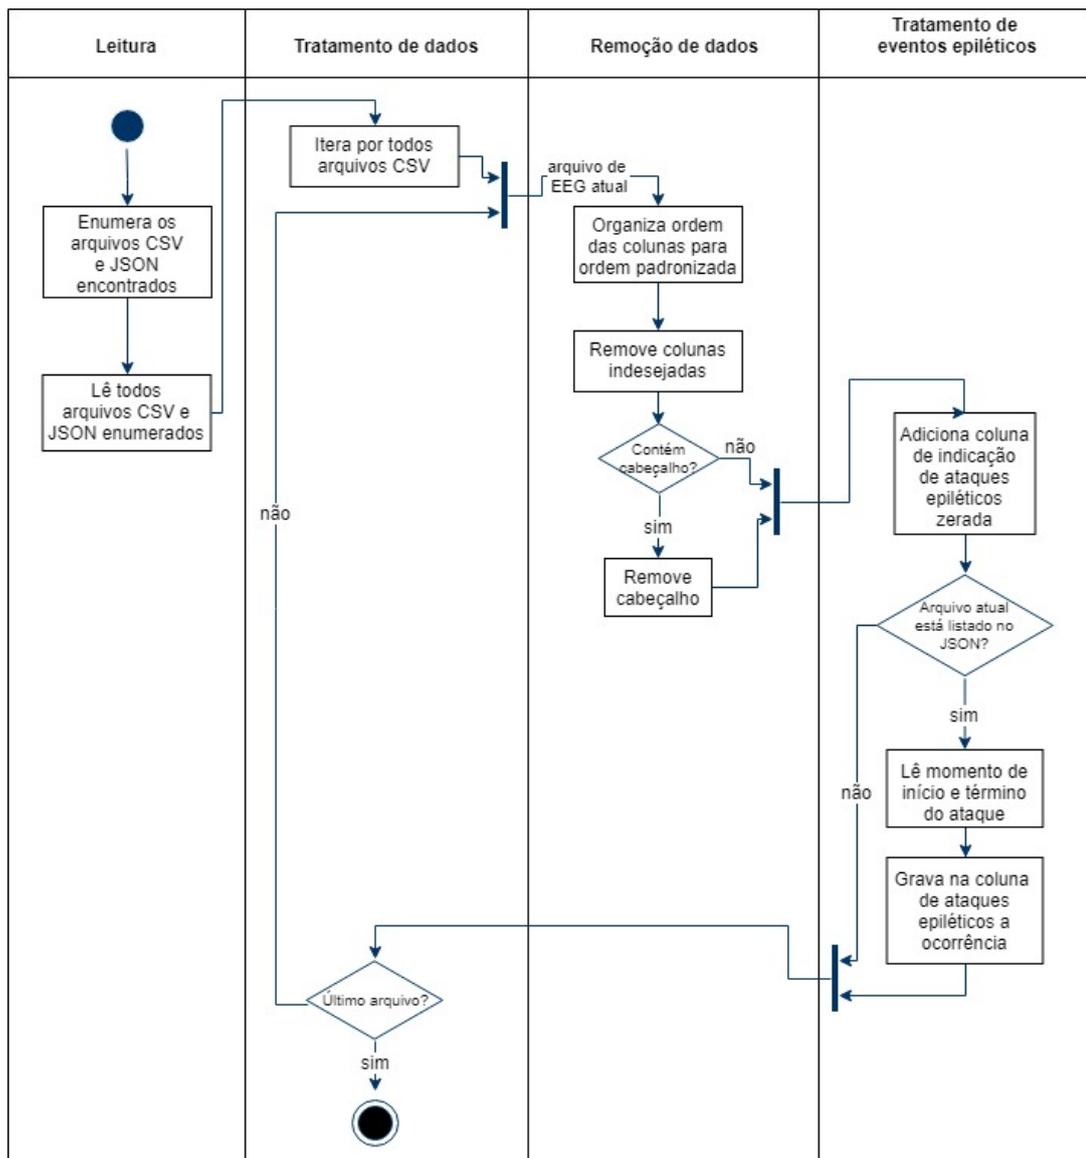


Conforme o diagrama de classes exibido na Figura 9, é possível ver que um primeiro elemento denominado “EegFiles” é uma coleção que relaciona todos os arquivos com extensão CSV de pacientes encontrados na pasta raiz de execução do algoritmo. Nesta

coleção podem haver diversas entradas de objetos identificando o nome do arquivo do qual se quer listar os eventos epiléticos, sendo esses objetos sumarizados no diagrama por “arquivo.csv”. Dentro desses objetos há uma lista de objetos de ataques epiléticos denominada por “*seizures*”. Por fim os objetos de eventos epiléticos possuem cada um uma propriedade que indica o instante de início do ataque epilético (em segundos), com o nome “*seizureStartSecond*”, e o instante de término do evento, com o nome “*seizureEndSecond*”.

Uma vez obtidos os arquivos de EEG e os arquivos de marcação de tempo se criou um algoritmo de pré-processamento para adequação dos arquivos para o treinamento da rede neural, sendo o algoritmo desenvolvido utilizando-se a linguagem Python V. 3.6.2 (PYTHON, 2018) e o ambiente de desenvolvimento Jupyter Notebook (JUPYTER, 2018). O diagrama de atividades exposto na Figura 10 apresenta o funcionamento do algoritmo de tratamento de dados proposto neste trabalho.

Figura 10 – Diagrama de atividades do algoritmo de tratamento de dados utilizado para adequação dos arquivos utilizados no treinamento da rede neural.



O diagrama de atividades da Figura 10 trata em seu princípio da enumeração e leitura de todos arquivos de EEG, no formato CSV, e todos arquivos de marcação de tempo, em formato JSON, presentes no mesmo diretório que o algoritmo. Terminada a leitura de arquivos, é feita a iteração por todos arquivos de EEG. Para cada arquivo no laço de iteração são organizadas as colunas conforme o padrão recorrente encontrado na maioria dos arquivos de EEG do banco de dados. Após a organização, são removidas as colunas que contêm canais indesejados, incluindo colunas vazias que foram postas somente para melhor organização dos dados em alguns arquivos (PHYSIONET, 2018a). Juntamente com colunas indesejadas, é removido o cabeçalho que indica unidade de medida de cada coluna. Juntando os dados dos arquivos de marcação de tempo (com extensão JSON) à informação da taxa de amostragem de 256 amostras por segundo, é possível gerar um vetor coluna de dados para ser o alvo de treinamento da rede neural do presente trabalho. Com a inserção dos eventos epiléticos se dá o fim do algoritmo ao percorrer todos arquivos no laço de iteração.

Quanto ao algoritmo de tratamento de dados ainda é válido observar algumas questões pontuais. É possível facilmente remover o passo de remoção de colunas desbalanceadas para mantê-las caso desejado, formando uma base desbalanceada (presença de determinados canais em somente alguns arquivos), o que pode ser desejado para uma mudança de abordagem no treinamento da ANN. Já quanto à marcação de eventos epiléticos, é crucial verificar que a taxa de amostragem de dados é multiplicada pelo tempo enumerado no arquivo JSON (nos atributos dos objetos *seizure*) para se obter a posição de entrada no arquivo de EEG (arquivos em formato CSV) correspondente ao instante em segundos, e então é identificado com um "1" a ocorrência de um ataque epilético. O processo de identificação de ocorrência de ataques epiléticos só é feito caso haja a presença do nome do arquivo de EEG atual no objeto de identificação de arquivo CSV na estrutura do arquivo com extensão JSON da Figura 9.

De modo a se obter somente pontos referentes ao Sistema 10-20, incluindo adaptações de nomes de alguns eletrodos (KLEM *et al.*, 1999), e mantendo somente os eletrodos que fossem comuns a todos arquivos utilizados, formando assim uma base artificialmente balanceada (sem o uso de nenhum critério científico para extração de dados de conjunto de dados) em número de canais, foram removidos os canais desbalanceados e ignorados os arquivos que não contivessem todos os eletrodos balanceados, também referidos aqui como “canais padrões”.

Após realizado o tratamento de dados, a matriz construída em cada arquivo EEG se constitui de uma primeira coluna evidenciando o tempo decorrido desde o início da gravação até o momento de registro da linha atual, em seguida há 18 colunas, cada uma contendo a leitura de diferença de potencial de um canal de EEG em relação a um segundo canal. Por fim há a coluna que evidencia de forma binária se o dado atual foi registrado

durante a ocorrência de um ataque epilético, o que foi identificado clinicamente durante o registro de dados no hospital (PHYSIONET, 2018a).

Buscando exemplificar a organização de cada arquivo processado para treinamento das redes neurais do presente trabalho, é possível ver na Tabela 5 uma representação da organização dos arquivos formados para treinamento e teste das redes.

Tabela 5 – Organização dos arquivos utilizados nas redes neurais do presente trabalho. Tempo decorrido desde o início da gravação, canais de leitura de diferença de potencial em microvolts com identificação dos pontos do Sistema Internacional 10-20 utilizado, e coluna final indicando se durante a gravação do dado estava ocorrendo um ataque epilético.

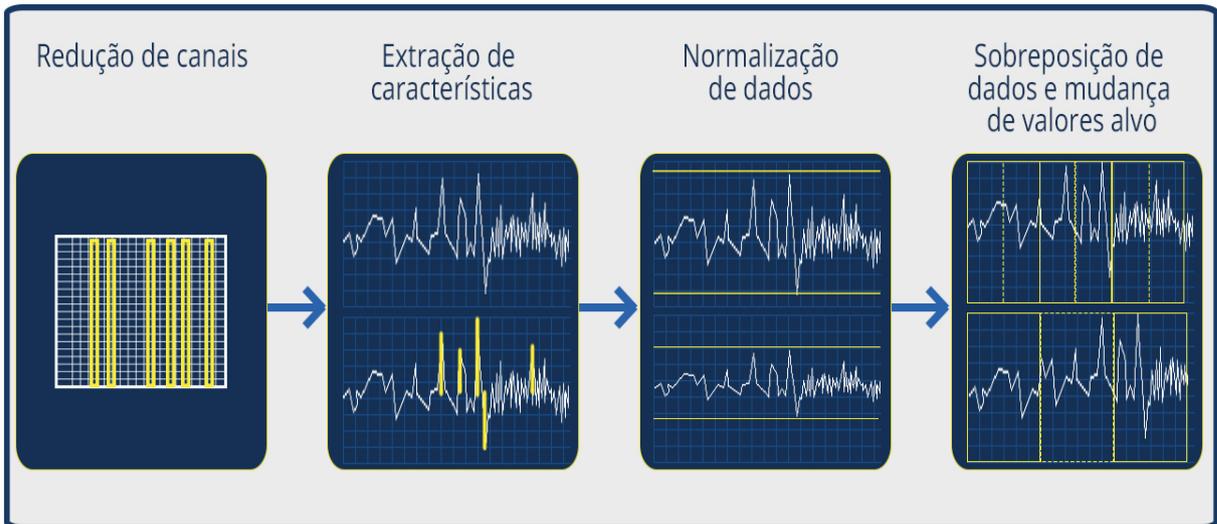
Tempo decorrido (hh:mm:ss.mmm)	Canal 1: FP1-F7	Canal 2: F7-T7	Canal 3: T7-P7	...	Canal 18: final	Ocorrência de ataque epilético
0:2:51.598	18.559	15.629	12.698		21.49	0
0:2:51.602	20.513	27.35	9.768		2.93	0
0:2:51.605	-4.884	39.072	6.838		-1.954	1
0:2:51.609	-8.791	33.211	0		-5.861	1

Com a obtenção da organização mostrada na Tabela 5 se encontra concluído o processo planejado de tratamento e adequação de dados para treinamento da ANN do presente trabalho.

3.3 PRÉ-PROCESSAMENTO DE DADOS

Visando o treinamento apropriado da ANN, o pré-processamento de dados atua como uma etapa importante nesse processo, de forma a se obter e conformar características matemáticas com maior probabilidade (a partir de testes preliminares) de correlação com os períodos pré-ictais. A Figura 11 representa as etapas de pré-processamento relatadas a seguir.

Figura 11 – Etapas de pré-processamento adotadas.



Devido ao excessivo volume de dados de entrada, é proposta uma redução de canais utilizados, visando mitigar os problemas associados. Um vez definidos os canais de entrada, é realizada a extração de características. Para tanto é considerado que os dados brutos a serem processados apresentam elevada variação devido à sua natureza fisiológica. Então conforme analisado na seção sobre a fisiologia do Cérebro humano e na revisão bibliográfica, é perceptível que as características espectrais são pertinentes na análise de extração de características. Adicionalmente, por se tratar de sinais estocásticos, a utilização de parâmetros probabilísticos é considerada na caracterização de períodos referentes aos eventos epiléticos. Após extraídas as características são conformados os dados (normalização dos dados de entrada e categorização dos alvos) visando um apropriado treinamento da ANN, ou seja, ajustando limites de dados de entrada e características para adequada comparação e correspondente segregação dos valores alvos em classes. Por fim são utilizadas abordagens de sobreposição de dados de entrada e de antecipação de valores alvo de treinamento com o intuito de aumentar a antecedência da detecção de um evento epilético futuro.

3.3.1 Redução de canais

Conforme observado após a análise da Tabela 4, a base de dados de treinamento envolve 104 horas de aquisição de sinais de EEG, gerando um grande volume dados. Esse grande volume de dados é algo desejável para apropriado treinamento de uma ANN, visto que expõe a rede a diversos dos cenários possíveis que possam ocorrer, generalizando da melhor forma a mesma. Entretanto a utilização de todos os canais descritos na discussão relacionada à Tabela 3 incorre na necessidade de uma grande carga computacional para todas as operações matemáticas e operações de reestruturação em geral dos dados de EEG, além de fatores práticos como maior complexidade de aquisição, custos relacionados,

consumo de energia e tempo de leitura para aparelhos de aquisição portáteis, desconforto de pacientes e em especial o sobreajuste, ou *overfitting*, decorrente do uso de vários canais redundantes (ALOTAIBY *et al.*, 2015). A partir do tratamento e pré-processamento, para cada canal de EEG se aumenta linearmente o número de dados a cada característica extraída dos mesmos, o que é indesejável do ponto de vista de carga computacional e sobreajuste.

Dados os problemas apresentados quanto ao número excessivo de canais de aquisição, visando mitigá-los tanto na aquisição quanto no tratamento e análise de sinais de EEG, foram conduzidos estudos de forma a avaliar a redução do número de canais e seu impacto na determinação de eventos epiléticos.

A investigação de (ALOTAIBY *et al.*, 2015) enumerou diversas pesquisas realizadas para redução ou seleção de canais de EEG para diversas aplicações, investigando em boa parte aplicações voltadas para a classificação de eventos epiléticos. Dentre as pesquisas investigadas algumas demonstraram resultados especialmente interessantes, assim como, demais trabalhos não listados nessa investigação mas relacionados a essas pesquisas, conforme relatado a seguir.

(GREENE *et al.*, 2008) investigaram a utilização de um único canal e sua performance em relação com treinamentos utilizando todos os 7 a 11 canais disponíveis em uma base de dados de monitoramento de eventos epiléticos em pacientes neonatais, obtendo para o canal C3-C4 variações de menos de 10% em relação ao uso de todos os canais nas métricas de taxa de acerto, *sensitivity* e *specificity*. Já no trabalho de (BIRJANDTALAB *et al.*, 2017), o qual utilizou a mesma base de dados (PHYSIONET, 2018a) do presente trabalho, identificou três canais com maior contribuição para o algoritmo de Árvores de Decisão, sendo para o paciente chb1 os canais FZ-CZ, F3-C3 e P3-O1 os canais que apresentaram maior contribuição. O autor desse artigo ressalta que a seleção de canais seria específica por paciente mas somente demonstra os canais mais relevantes para o paciente chb1, o que, apesar de incompleto, pode servir de comparação para os canais encontrados em outros trabalhos.

Também fazendo uso da mesma base de dados do presente trabalho, (CHANG *et al.*, 2012) avaliaram a performance da utilização de 6, 5, 4, 3 e 2 canais na predição de eventos epiléticos, resultando em 75 combinações. Com todos os 22 canais a taxa de acerto foi de 60%, já com 6 e 5 canais, foi possível alcançar taxas de acerto ainda maiores, chegando a 70%. Com a utilização de 4 e 3 canais foi possível se obter a mesma taxa de acerto observada com 22 canais. (CHANG *et al.*, 2012) utilizaram 2 dos 3 canais observados no trabalho de (BIRJANDTALAB *et al.*, 2017), sendo eles F3-C3 e P3-O1, entretanto não usaram o canal C3-C4 destacado por (GREENE *et al.*, 2008) na determinação de eventos epiléticos em neonatais. Analisando todos os resultados com taxa de acerto igual ou superior à obtida com 22 canais, se obtém os resultados resumidos na Tabela 6.

Conforme as maiores taxas de acerto dispostas na Tabela 6, verifica-se que os canais que apresentaram maior participação dentre os melhores resultados foram, em ordem decrescente, F7-T7, F8-T8, FP2-F8 e T8-P8, tendo percentual de participação dentre os melhores resultados de 87%, 67%, 60% e 53%, respectivamente.

Embora haja canais que isoladamente não apresentem as melhores performances, mas quando combinados possam agregar características que resultem em boas performances, analisando o estudo de (CHANG *et al.*, 2012) e a Tabela 6, é proposto no presente trabalho a utilização de 4 canais de maior frequência dentre os melhores resultados obtidos com redução de canais de EEG na determinação de eventos epiléticos, sendo eles F7-T7, F8-T8, FP2-F8 e T8-P8. Porém, é importante destacar que é necessário, na continuidade deste trabalho, um estudo aprofundado através de um Projeto de Experimentos e sua correspondente validação estatística para certificar os estudos citados, assim como, a escolha dos correspondentes canais utilizados no presente trabalho. Os demais estudos abordados sobre redução de canais na determinação de eventos epiléticos embora demonstrem resultados interessantes, esses tratam ou de bases de neonatais, o que não configura o perfil dos pacientes da base de dados (PHYSIONET, 2018a) utilizada no presente trabalho, ou claramente observaram que os resultados eram específicos a um paciente, não havendo mais informações sobre os canais determinados para os demais pacientes, o que poderia levar a análises como a realizada na Tabela 6:

Tabela 6 – Combinações de canais de EEG para predição de eventos epiléticos com taxas de acerto iguais ou maiores que a taxa de acerto utilizando 22 canais.

Canais	Taxa de acerto
F7-T7, T7-P7,F4-C4,C4-P4,F8-T8,T8-P8	70%
F7-T7, T7-P7,F3-C3,C3-P3,P4-O2,P8-O2	65%
FP1-F7,F7-T7,T7-P7,P7-O1,P4-O2,P8-O2	65%
P7-O1, P3-O1,F4-C4,C4-P4,F8-T8,T8-P8	65%
F7-T7, T7-P7,P3-O1,P4-O2,F8-T8,T8-P8	65%
F7-T7, T7-P7,F3-C3,P4-O2,F8-T8,T8-P8	60%
F7-T7,T7-P7,F3-C3,C3-P3, P4-O2	70%
F7-T7,T7-P7,P4-O2,F8-T8, T8-P8	60%
F7-T7,F4-C4,C4-P4,F8-T8, T8-P8	60%
F7-T7,T7-P7,F3-C3,P4-O2, P8-O2	60%
F7-T7,T7-P7,F3-C3,FP2-F4,FP2-F8	60%
F7-T7,C3-P3,C4-P4,F8-T8	60%
F4-C4,C4-P4,F8-T8,T8-P8	60%
F7-T7,F4-C4,F8-T8,T8-P8	60%
F7-T7,P3-O1,F8-T8	60%

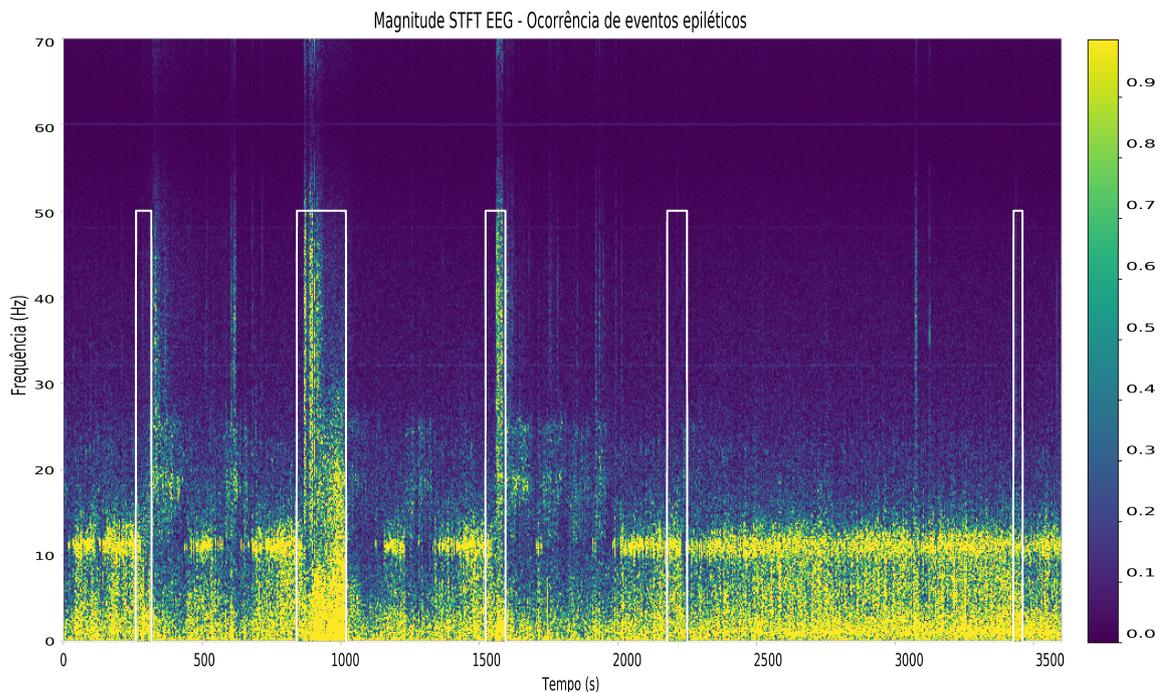
Fonte: Adaptado de (CHANG *et al.*, 2012).

3.3.2 Extração de características

Dentre as técnicas de pré-processamento possíveis, a extração de características dos sinais de EEG analisados é uma tentativa de se obter características matemáticas que caracterizem os sinais de EEG através da transformação dos dados brutos adquiridos dos pacientes.

De forma a ilustrar a natureza dos sinais de EEG dos quais se deseja extrair características que ajudem a identificar períodos ictais, na Figura 12 é possível visualizar a Transformada de Fourier de Curto Tempo ou *Short Time Fourier Transform* (STFT) juntamente com a identificação de eventos epiléticos para um dos sinais da base de dados do presente trabalho.

Figura 12 – STFT de um sinal de EEG juntamente com a marcação da ocorrência de eventos epiléticos registrados. Ilustração das variações temporais e espectrais características de eventos epiléticos.

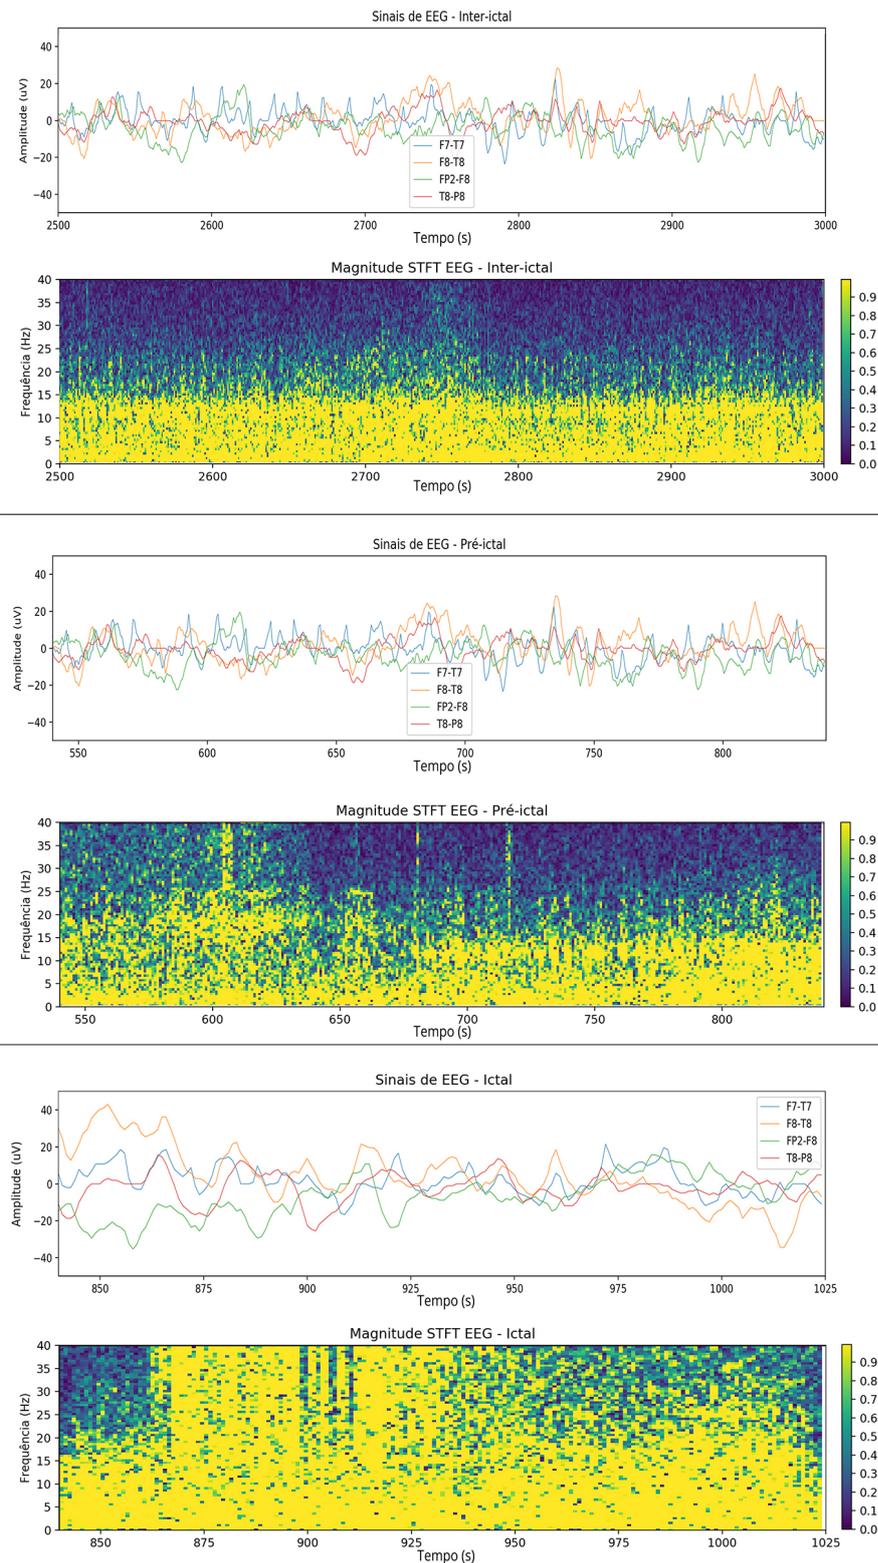


Conforme observado na Figura 12, há variações temporais e espectrais abruptas na iminência e na ocorrência de eventos epiléticos (destacados por retângulos claros sobrepostos ao gráfico). Variações similares ocorrem em outros trechos sem eventos epiléticos, como logo após de 500 e 3000 segundos, indicando a princípio que não há um padrão coerente de variações em relação aos eventos epiléticos, mas deve-se ponderar que não somente a característica em frequência caracteriza as regiões de interesse, mas sim um conjunto de características consideradas simultaneamente no treinamento da ANN.

Com o intuito de melhor avaliar o comportamento espectral para diferenciação de regiões inter-ictais, pré-ictais e ictais, na Figura 13 é exibida uma visualização mais

pormenorizada das componentes espectrais em tais regiões, utilizando o mesmo caso da Figura 12 com a análise do canal F7-T7, juntamente com o sinal de EEG não tratado, dos quatro canais selecionados para análise.

Figura 13 – Análise espectral de regiões inter-ictais, pré-ictais e ictais do canal F7-T7 com o uso de STFT. Exibição gráfica da leitura de EEG dos quatro canais selecionados para o trabalho.



Ao analisar a Figura 13, é possível ver que os sinais não tratados de EEG para as regiões ictais e inter-ictais são muito semelhantes, somente os sinais ictais visualmente distintos apresentando grandes variações de amplitude entre os canais. Entretanto as componentes espectrais apresentam padrões mais distintos para cada uma das regiões, tendo as regiões pré-ictais componentes espectrais variantes no tempo, as quais são de certa forma semelhantes às componentes das regiões ictais.

Embora não seja absoluta, a análise espectral traz informações importantes a respeito das faixas cerebrais em atuação. Portanto, através dessa breve análise visual e do conhecimento a respeito da relação entre eventos epiléticos e faixas cerebrais, assim como variações abruptas de sinais de EEG, as variações em amplitude e em frequência são consideradas relevantes na presente análise para caracterização de períodos ictais.

Analisando o formato dos sinais de EEG é possível perceber que há a presença de muitos picos esparsos ao longo do tempo, tendo esses picos correlação com atividades cognitivas específicas, assim como, com eventos epiléticos, conforme analisado por (NUNEZ; SRINIVASAN, 2006). Dada a característica de constante variação em amplitude e presença de picos, é considerado, no presente trabalho, características temporais como o Valor Quadrático Médio ou *Root Mean Square* (RMS), desvio padrão e número de picos observados acima de um determinado limiar.

O valor RMS de um sinal arbitrário é descrito pela Equação (8), onde N é o número de amostras analisadas e x é a magnitude das amostras analisadas.

$$RMS = \sqrt{\frac{1}{N} \int_0^N x[n]^2 n} \quad (8)$$

Já o desvio padrão é calculado conforme a Equação (9), sendo X_i o valor atual sendo analisado, μ o valor médio do sinal ou conjunto de amostras, e N o número de amostras.

$$\sigma = \sqrt{\sum_{i=1}^N \frac{(X_i - \mu)^2}{N - 1}} \quad (9)$$

Finalmente para a contagem do número de picos acima de um limiar simplesmente se determinou um valor fixo de 80% acima da média do sinal, sendo esse valor um limiar que apresentou detecção de picos satisfatória através de testes preliminares, e foram somadas todas as ocorrências identificadas no intervalo de um segundo, replicando esse valor para todas as entradas contidas em um segundo, sendo 256 nesse caso devido à taxa de amostragem. A análise por janelas também é utilizada em outras características, como descrito a seguir.

Conforme evidenciado na Revisão Bibliográfica e também constatado na Figura 12, as características extraídas apresentam variações abruptas em certos períodos nos sinais de EEG. Especialmente em sinais de EEG de indivíduos epiléticos, são observados picos de sinais de baixas frequências como ondas alfa e theta tanto em períodos inter-ictais como pré-ictais, entretanto na ocorrência de um evento epilético se observa a ocorrência de uma súbita mudança de frequências e o surgimento de ondas polimórficas de duração prolongada, com um certo decréscimo em frequência mas com aumento em amplitude (TZALLAS *et al.*, 2012) (SIULY; LI; ZHANG, 2016). Dada a natureza deste tipo de biosinal foram extraídas características espectrais como a FFT e a Densidade Espectral de Energia ou *Power Spectral Density* (PSD).

Tanto a FFT quanto a PSD são obtidas a partir do cálculo da STFT de todas N entradas de uma gravação de EEG de um paciente, isto é, 1 hora de dados. A partir do cálculo da STFT se obtém segmentos temporais e espectrais descrevendo as componentes espectrais do sinal ao longo do tempo. A obtenção da STFT é descrita pela Equação (10), onde $x[n]$ é o sinal de entrada na amostra n , $w[n - m]$ é uma janela (função aplicada a cada segmento analisado) com o intuito de suavizar as extremidades dos segmentos de dados para evitar o surgimento de componentes indesejadas no espectro de frequências. O resultado $X(m, \omega)$ é uma função variável tanto no tempo como em frequência, sendo m (discreto) o tempo ou amostra e ω a frequência (contínua) do espectro obtido, com valor igual a $\frac{2\pi k}{N_{seg}}$, com N_{seg} sendo o número de amostras por segmento. É importante observar que ω se refere à frequência do espectro resultante e w se refere à janela aplicada a cada segmento.

$$STFT\{x[N_{seg}]\} = X(m, \omega) = \sum_{n=-\infty}^{\infty} x[n]w[n - m]e^{-j\omega n} \quad (10)$$

A janela escolhida foi a do tipo Hanning, com tamanho da janela de 512 amostras, com sobreposição de 50% entre janelas, e a taxa de amostragem de 256 Hz, a qual apesar de ser igual à taxa de amostragem dos dados não possui relação somente com esta, visto que a taxa de amostragem para a STFT é relacionada também ao tamanho dos segmentos analisados. A escolha desses valores é devido ao melhor ajuste entre resolução em frequência e resolução no tempo, dado que quanto maior a janela, melhor é a resolução em frequência e quanto menor a janela, melhor a resolução no tempo, conforme o Princípio da Incerteza de Heisenberg (BUSCH; HEINONEN; LAHTI, 2007).

A partir da STFT se pode obter um vetor de comprimento igual à razão do número de entradas original N e a taxa de amostragem. Cada vetor contém o espectro de frequências de 0 a $\frac{N_{seg}}{2}$ Hertz. A combinação de coordenadas temporais e espectrais resulta na intensidade do sinal de EEG de determinada entrada em certa componente espectral.

A utilização dessa transformada facilita o processo de obtenção de segmentos temporais e espectrais dos sinais de EEG com sobreposição e aplicação de janelas.

Através da análise do resultado da STFT, nota-se que m é um ponto temporal do resultado temporal-espectral obtido a partir da STFT, entretanto m não é necessariamente um valor correspondente à entrada n do sinal original da FFT $x[n]$. Para se obter uma relação direta, é aplicado para todo m o mesmo valor $X(\omega)|_m$ a vetores de valor unitário e comprimento igual à razão entre o número total de pontos do sinal de entrada N e tamanho do vetor temporal M compreendido de 0 a m , conforme a Equação (11). Dessa forma é obtida uma relação de 1 para 1 entre o vetor temporal de entrada e saída da STFT em detrimento da resolução geral do resultado, porém permitindo a análise dos valores de FFT e PSD através da criação de vetores de treinamento de mesmo comprimento que o sinal de EEG original.

$$X(n, \omega) = (1_0, \dots, 1_{i-1}, 1_i) \Big|_{i=0}^{i=N/M} X(m, \omega) \forall m \quad (11)$$

Dado o vetor $X(n, \omega)$, se obtém a FFT para cada ponto m a partir do módulo de $X(\omega)$, conforme mostrado na Equação (12):

$$FFT|_m = X(\omega)|_m \quad (12)$$

Finalmente através do quadrado do módulo de $X(n, \omega)$, se obtém a PSD, conforme a Equação (13).

$$PSD|_m = |X(\omega)|_m|^2 \quad (13)$$

A PSD indica a densidade de energia verificada nas componentes espectrais, sendo um indicativo do quão significativa é ou não determinada componente espectral em um certo segmento de dados analisado.

A partir da obtenção das características espectrais se torna possível a seleção de determinadas frequências para análise. Dadas as faixas de ondas cerebrais expostas na Tabela 1, é decidido a utilização de uma frequência dentre cada uma das quatro primeiras faixas, visto que, como analisado na Revisão Bibliográfica sobre o sinal de EEG e métodos usuais de predição de ataques epiléticos, essas faixas apresentam maiores variações na presença de eventos epiléticos. Portanto são escolhidas para análise as componentes espectrais centradas em 4Hz, 8Hz, 13Hz e 18 Hz, amostrando componentes espectrais das faixas delta, theta, alfa e beta, respectivamente.

3.3.3 Normalização de dados e categorização de alvos

A extração de características empregada envolve a obtenção de dados de diferentes significados físicos e matemáticos com relação aos dados de EEG iniciais. Conforme analisado na Revisão Bibliográfica sobre os sinais de EEG, os dados obtidos a partir desta técnica representam potenciais elétricos captados a partir de campos elétricos gerados por impulsos elétricos cerebrais. Uma característica obtida pelo módulo da FFT representa a magnitude de cada componente espectral do sinal de potencial elétrico, isto é, a FFT calcula uma magnitude para cada frequência presente em um sinal analisado. Os dados de EEG e FFT possuem magnitudes numéricas de diferentes ordens de grandeza, e eventualmente irão interagir no processo de treinamento e posterior predição da ANN, logo é recomendado que sejam normalizadas de forma a terem bases de comparação semelhantes, com extensão ou limites numéricos iguais (GUYON *et al.*, 2006). No presente trabalho o método utilizado para normalização foi o Min-Max, conforme mostrado na Equação (14):

$$MinMax(x[n]) = \frac{x[n] - \min(x)}{\max(x) - \min(x)}(\max - \min) + \min \quad (14)$$

A Normalização Min-Max calcula para cada entrada a razão entre sua diferença com relação ao valor mínimo observado para o conjunto de dados, então esse valor é multiplicado pela diferença entre o máximo e mínimo da escala adotada, por fim somando esse resultado ao mínimo da escala adotada. Esse tipo de normalização preserva a relação entre os dados originais (OGASAWARA *et al.*, 2010), o que é assumido no presente trabalho como um critério relevante a ser mantido. É utilizada uma escala com mínimo igual a -1 e máximo igual a 1 de forma a preservar a característica da escala original de contemplar valores negativos e positivos. Dado que a normalização deve ser igual para todos os arquivos processados de forma a se estabelecer uma base de comparação, os valores máximos e mínimos do conjunto de dados, referenciados na Equação (14) como $\max(x)$ e $\min(x)$, respectivamente, são obtidos a partir de um arquivo selecionado de forma aleatória no conjunto de arquivos de treinamento, de forma a minimizar um viés de seleção que possa impactar na performance da rede caso um mesmo arquivo fosse sempre utilizado para obter os parâmetros de normalização.

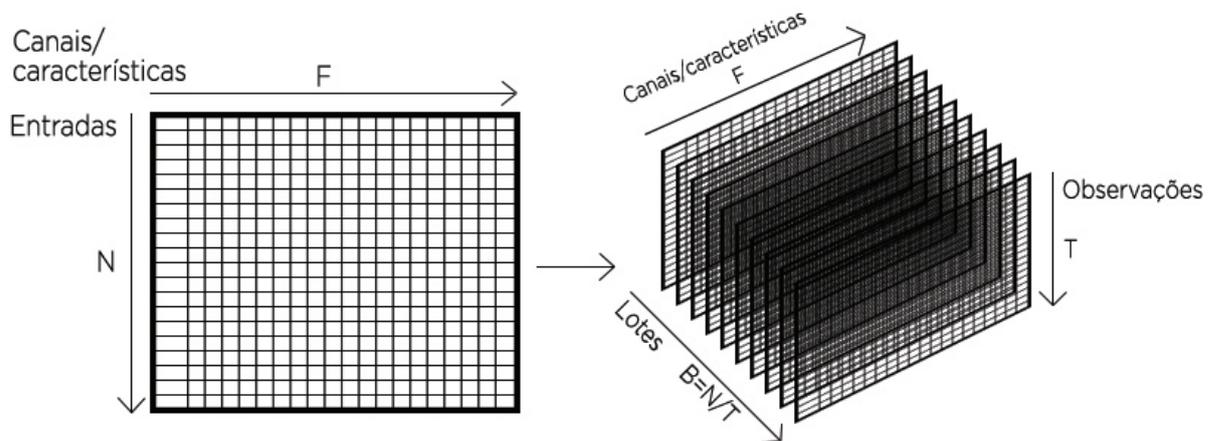
Após normalizados os dados há a etapa de categorização dos valores alvos, procedimento também conhecido como *one-hot encoding*. Nessa etapa os valores que descrevem se está ou não havendo um ataque epilético para uma determinada entrada, como visto na última coluna da Tabela 5, são convertidos para um vetor de dimensão igual ao número de categorias presentes nos dados, onde todos valores são zero a exceção do dado na posição correspondente à categoria. Para o presente caso só há a categoria 0 que indica que não está havendo um ataque epilético e a categoria 1 que indica que está ocorrendo. O vetor alvo passa de uma dimensão (com valores 0 ou 1) para um vetor bi-dimensional, assumindo

valor $[1,0]$ para a categoria 0 e valor $[0,1]$ para a categoria 1. Dessa forma é possível fazer com que a ANN classifique categorias ao invés de valores. Essa categorização também se demonstra útil caso houvesse mais classes, gerando vetores de fácil interpretação para a ANN no momento de treinamento, visto que não há diversos valores contínuos entre categorias, mas somente opções discretas descrevendo cada uma separadamente.

Poderia-se também utilizar somente um um valor de alvo, de forma que a ANN realizaria a classificação a partir da determinação de um valor limiar para o qual predições acima de um limiar representariam uma classe, como a classe 1, e abaixo do limiar a outra classe, como a classe 0. Entretanto foi utilizada a categorização de alvos de forma a generalizar alvos que poderiam ser expandidos para mais classes em uma possível continuação deste trabalho, como a separação entre alvos para classificação de regiões ictal, pré-ictal e inter-ictal.

A normalização dos dados termina com o redimensionamento dos mesmos em lotes ou *batches*, conforme visto na Figura 14. Um número de entradas N é dividido em B lotes, possuindo cada lote T observações ou entradas, sendo B a razão entre o número de entradas total N do conjunto de dados e o número de observações T . O número de observações de cada lote também é chamado de *time steps*.

Figura 14 – Divisão dos conjuntos de dados em lotes e observações.



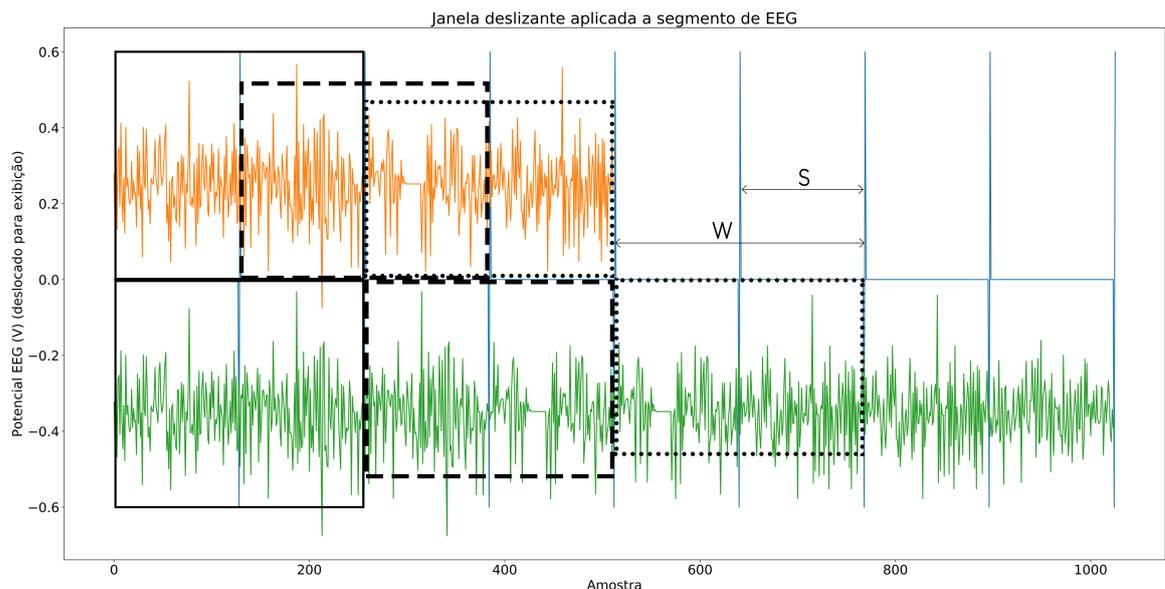
O propósito principal da divisão dos dados em lotes reside na diminuição da carga computacional, devido à grande dimensionalidade dos dados que inviabiliza a análise de todas as entradas em uma única sequência. Optou-se neste trabalho pelo uso de lotes de 1 segundo, ou seja, com 256 observações por lote e 3600 lotes por arquivo de EEG, visto que há uma hora de gravação de sinais de EEG por arquivo de cada paciente a uma taxa de amostragem de 256Hz, resultando em $N = 3600 * 256$. Essa divisão se reflete na arquitetura da rede LSTM, fazendo com que a mesma tenha que ser adaptada para entrada de fluxos de dados parametrizados conforme o número de lotes e observações dentro de cada lote.

3.3.4 Sobreposição de dados de entrada e mudança de valores alvo

De forma a tentar aumentar a antecedência da predição de ocorrências de eventos epiléticos, são empregadas duas técnicas de pré-processamento, atuando somente nos valores de treinamento, de forma que a ANN seja treinada com esses dados pré-processados para posteriormente gerar predições antecipadas quando exposta a dados que não sofreram tais processos.

Uma abordagem para tentar antecipar as predições de eventos epiléticos é a sobreposição dos dados através da replicação dos mesmos com a técnica de segmentação denominada de janelas deslizantes. Tipicamente é definida uma janela que percorre todo o conjunto de dados de entrada de treinamento criando uma nova matriz de dados de entrada constituída primeiramente dos dados do início do conjunto de treinamento até o fim da janela, adicionados da próxima sequência de dados de entrada desde o índice dado pelo passo da janela deslizante até o índice correspondente ao índice do passo mais o tamanho da janela. Este processo é ilustrado na Figura 15, onde o tamanho da janela é W e o passo realizado para a próxima janela é S . Nota-se na Figura 15 o sinal sobreposto (na parte inferior) a partir de três janelas aplicadas no sinal original (na parte superior), onde a altura das janelas, assim como o deslocamento vertical dos sinais, são alterados somente para melhor visualização.

Figura 15 – Sobreposição de dados de entrada (sinal superior) através da aplicação de janelas deslizantes de tamanho W e passo S , obtendo sinal com sobreposição (sinal inferior). Diferentes tracejados indicam diferentes janelas. Procedimento aplicado aos conjuntos de treinamento para antecipação das predições de eventos epiléticos.

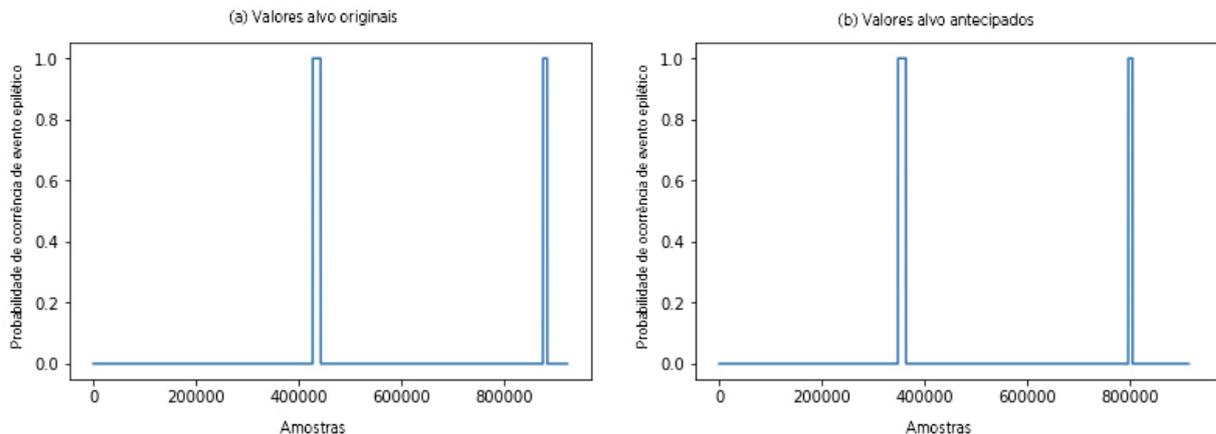


É definido no presente trabalho, de forma empírica, o uso de janelas de 1 segundo (256 entradas) e passos de 0,5 segundos (128 entradas), ou seja, 50% de sobreposição, expandindo o conjunto de treinamento para o dobro da sua extensão original. Dessa forma

pretende-se que a ANN seja exposta mais de uma vez a diversos dados. Uma consequência da aplicação de janelas deslizantes é que há a possibilidade de a ANN apreender melhor as sequências de dados que precedem os eventos epiléticos, especialmente nos segmentos de dados de entrada nos quais os alvos correspondem à ocorrência de eventos epiléticos, pois a sobreposição cria sequências artificiais com repetição de dados, e conseqüentemente expande (através de repetição temporal) os trechos referentes a eventos epiléticos.

Juntamente com a sobreposição de dados é aplicada uma abordagem onde se antecipa os valores alvo, baseando-se em (JAIN *et al.*, 2015), no qual se aplica para um conjunto parcial de dados o alvo verificado no fim do conjunto. A antecipação é feita deslocando os valores alvo para posições anteriores no tempo, de forma a mover os alvos positivos, os quais indicam a incidência de um evento epilético, para as seções pré-ictais. O deslocamento de alvos pode ser observado na Figura 16, onde a Figura 16a exibe o sinal original e a Figura 16b apresenta o resultado do deslocamento.

Figura 16 – Deslocamento de alvos para antecipação das predições de ataques epiléticos: (a) alvos originais e (b) alvos deslocados.



É utilizado no presente trabalho o deslocamento dos alvos em 5 segundos, através de escolha empírica. Desta forma pretende-se que a ANN tente classificar eventos pré-ictais ao indicar diretamente os alvos desses segmentos com o valor da categoria 1, e indicando parcialmente os segmentos ictais com alvos da categoria 0.

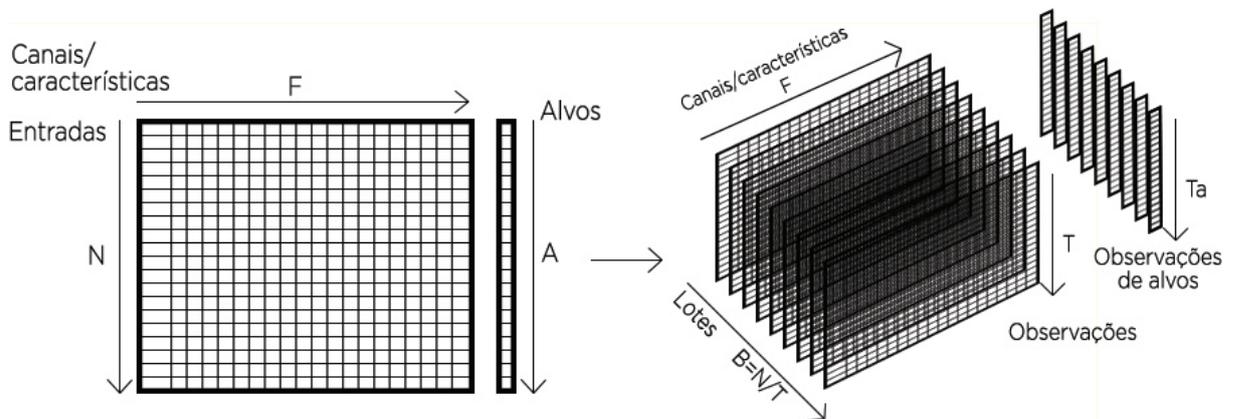
3.4 REDE RECORRENTE LSTM

O desenvolvimento e treinamento da rede LSTM é dependente da estrutura de dados de entrada e da saída desejada. No presente trabalho são analisadas entradas temporais de valores numéricos de leituras de EEG, isto é, fluxos de dados de números reais que possuem uma relação temporal. Já as saídas desejadas são classes mutuamente excludentes que indicam se, conforme a sequência de entradas processadas até o momento, há a previsão da ocorrência de ataques epiléticos em entradas futuras ou não. Esses aspectos configuram um problema de classificação baseados em séries temporais. Logo a rede LSTM deve ter a

capacidade de analisar seqüências de dados e classificar a predominância de uma classe indicando a alta ou baixa probabilidade de se estar em um período pré-ictal, e de forma excludente classificar a probabilidade de estar em um período inter-ictal ou ictal, de forma se ter uma distribuição probabilística entre todas classes presentes.

A Rede Neural Recorrente LSTM desenvolvida tem inicialmente células LSTM de entrada que computam lotes ou de dados de forma a gerar ao fim de cada lote uma saída para treinamento da rede. Foi optado pelo uso de lotes em função do elevado tamanho dos dados e pela não adequada capacidade de processamento do computador (Intel i5-3570 @ 3.4 GHz, memória RAM de 16GB@ 1.6 GHz, placa de vídeo GTX 970 @ 1.5 GHz com 4 GB de memória RAM) utilizado no treinamento (na ordem de Giga Bytes), sendo que somente se utilizou o mesmo computador durante todo desenvolvimento da rede de forma a se controlar a performance de treinamento conforme alterações na estrutura da rede. Uma representação da divisão dos dados em lotes pode ser vista na Figura 17, a qual expande a Figura 14 com representação dos alvos para melhor contextualizar o cenário de treinamento. É representado visualmente que a dimensão, ou número de dados nesse caso, das observações de entradas (T) e observações de alvos (Ta) é igual.

Figura 17 – Divisão dos conjuntos de dados de entrada e alvos em lotes e observações.



A divisão de cada conjunto de dados em lotes permite que se controle a quantidade de dados que serão processados pela rede até o momento em que seu estado interno é atualizado, uma saída oculta é gerada e então esses dados são passados como estados iniciais para o próximo lote de dados a ser analisado pela rede.

A rede desenvolvida processa tais dados de entrada utilizando diversas camadas de células LSTM. É utilizado no presente trabalho uma configuração na qual há três camadas de redes LSTM e uma camada de saída. As duas primeiras camadas LSTM possuem 30 células, retornando a cada observação uma saída, configurando uma arquitetura de várias entradas para várias saídas. Além disso essas duas primeiras camadas passam a cada lote subsequente os estados internos computados no último lote. A terceira camada possui 4

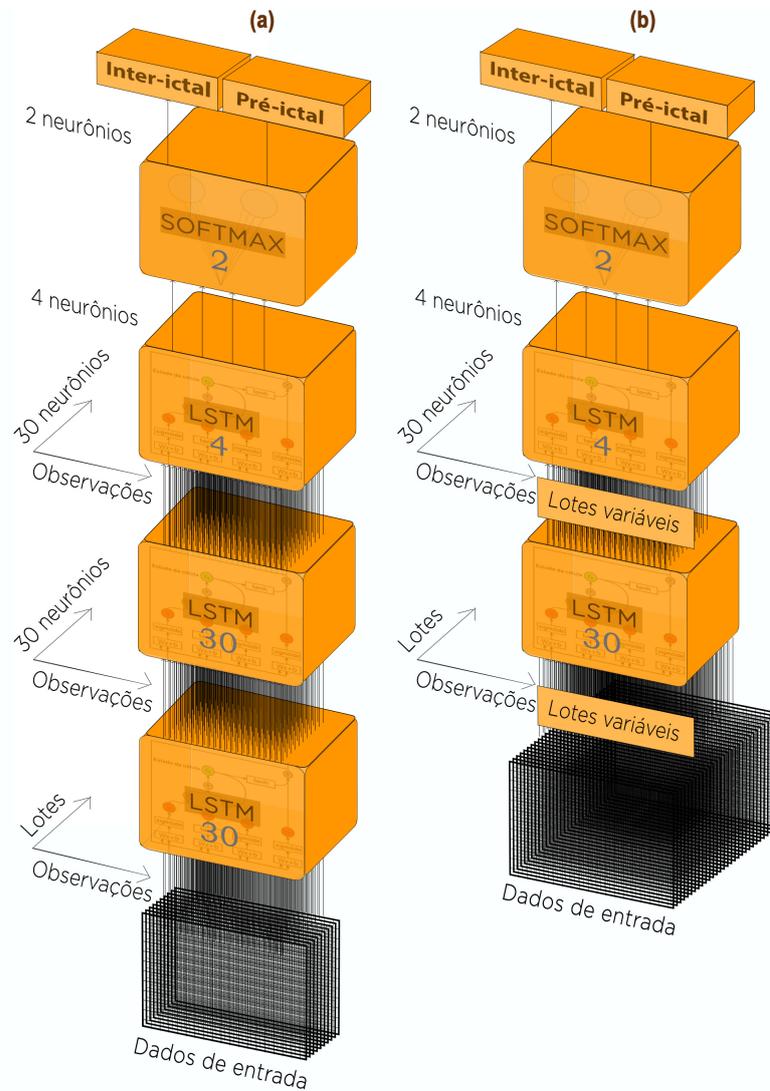
células, sendo este um valor aleatório escolhido com o critério de minimização de erros. Esta camada retorna uma saída apenas após analisadas todas observações de um lote, tendo uma estrutura de várias entradas para uma saída, e mantém o procedimento de passagem dos estados internos para os lotes seguintes. Por fim há uma camada com 2 neurônios e função de ativação *softmax*, a qual calcula de fato qual a probabilidade da sequência processada pertencer a cada uma das classes presentes. O diagrama da rede LSTM desenvolvida pode ser vista na Figura 18a, onde é representado o fluxo de dados de um lote. Devido a ANN realizar a classificação de qual classe deve pertencer a sequência analisada, a função de perda utilizada é a Entropia Cruzada Categórica, a qual se resume a aplicação de uma função de ativação *softmax* às saídas geradas pela ANN e então a aplicação de uma função de perda de Entropia Cruzada. A perda representa o quão distante a classificação categórica está do alvo categórico dos dados de treinamento.

O diagrama representado na Figura 18a corresponde à arquitetura geral utilizada quando não há sobreposição de dados. Entretanto na utilização de sobreposição, o formato de entrada da primeira camada LSTM é alterado para receber qualquer número de lotes, de forma que a extensão de dados é maior no treinamento e com tamanho normal nos testes. Para isso foi retirada a segunda camada de 30 neurônios que recebia sequências de tamanho definido, devido à sequência de matrizes possuir um tamanho variável, conforme visto na Figura 18b. Além disso não são mais passados a cada lote subsequente os estados internos computados no último lote, devido à mesma alteração na arquitetura da rede para aceitar qualquer quantidade de lotes.

Para o treinamento da rede são utilizadas 30 épocas, sendo este um valor para o qual o decréscimo de erro de treinamento e aumento da taxa de acerto têm variações muito pequenas ao se aumentar o número de épocas (conforme análise apresentada no Capítulo 4, Seção 4.1). Além disso, foi selecionada a partição do conjunto de dados entre 80% para treinamento e 20% para testes, evitando assim que a avaliação de performance induza a resultados que se apliquem somente ao conjunto de treinamento, dessa forma a avaliação também testa a capacidade de generalização da ANN ao se analisar a performance no conjunto de testes.

Definidos os parâmetros anteriormente mencionados é finalizado o desenvolvimento da ANN LSTM, sendo possível apresentar dados de treinamento para cálculo dos pesos entre os neurônios. Esse procedimento é feito através da técnica de Retropropagação Através do Tempo, ou *Backpropagation Through Time* (BPTT). Em BPTT há uma passagem direta tal qual em MLFFN onde não há a presença de estruturas recorrentes, então há uma passagem no sentido contrário com a diferença de que após serem atualizados os pesos da estrutura, o treinamento segue até processar todas observações no lote (para o caso do presente trabalho), desdobrando temporalmente a célula LSTM como se esta fosse

Figura 18 – Diagrama da ANN LSTM desenvolvida para classificação categórica de sinais temporais de EEG entre inter-ictal e pré-ictal. Representação do fluxo de dados para um único lote. O número em cada camada indica o número de células ou neurônios: (a) diagrama da arquitetura geral e (b) diagrama da arquitetura para sobreposição de dados.



uma MLFNN com cada observação sendo a entrada de somente uma MLFNN, tal qual observado na Figura 6.

Uma vez treinada a ANN, se faz necessário a avaliação dos resultados gerados pela mesma frente a novos dados. A métrica de avaliação da performance da ANN é baseada na detecção de sinais como impulsos ou janelas de detecção entre 5 a 60 segundos antes da ocorrência de um evento epilético, sendo esses valores arbitrados como um período próximo ao evento epilético mas com certa antecedência para que seja possível a tomada de ações necessárias por pacientes epiléticos ou indivíduos relacionados a esses. Outros valores de tempo de detecção também são avaliados de forma resumida (conforme análise apresentada no Capítulo 4, Seção 4.1).

Para avaliar as predições da ANN são utilizadas matrizes de confusão. Essas expõem a *sensitivity* (capacidade de identificar corretamente ocorrências de eventos epiléticos) e a *specificity* (capacidade de identificar corretamente a não ocorrência de eventos epiléticos ou períodos inter-ictais). A *sensitivity* exposta nas matrizes de confusão é calculada através da razão da contagem de todas as predições verdadeiro positivas (VP) e a soma de todos verdadeiro positivos e falsos negativos (FN) presentes nos dados analisado, conforme representada na Equação (15):

$$Sensitivity = \frac{VP}{VP + FN} \quad (15)$$

A *specificity*, calculada conforme a Equação (16) é o recíproco da *sensitivity* para períodos onde não há ocorrência de eventos epiléticos, ou seja, é a razão de todas predições verdadeiro negativas (VN) e a soma de todos verdadeiro negativos e falso positivos (FP) esperados conforme os dados utilizados no teste da ANN.

$$Specificity = \frac{VN}{VN + FP} \quad (16)$$

Com as métricas de avaliação estabelecidas é testada a ANN LSTM comparando os resultados obtidos com dados novos (dados específicos para teste). Na eventualidade da falha na predição antecipada de eventos epiléticos, a análise passa a ser no sentido de verificar a capacidade da ANN em atuar como classificadora de eventos ictais, ou seja, a capacidade de predições com tempo de antecipação nulo.

A título de verificação de reprodutibilidade, são aqui registrados os recursos computacionais utilizados no presente trabalho. O treinamento da ANN e testes foram realizados com um computador com processador Intel i5-3570 @ 3.4 GHz, memória RAM de 16GB @ 1.6 GHz, placa de vídeo GTX 970 @ 1.5 GHz com 4 GB de memória RAM.

4 RESULTADOS E DISCUSSÕES

Através da adequação, pré-processamento e aplicação de diferentes técnicas nos sinais de EEG dos pacientes, assim como a aplicação de técnicas na estrutura da ANN LSTM desenvolvida, foram realizados testes que geraram resultados que serão a linha de pesquisa para observar a aplicação de novos dados de EEG, sendo esses novos dados adequados com extração apropriada de características, conformados adequadamente e organizados em fluxos tais quais como definido na metodologia apresentada.

De forma a se avaliar as técnicas empregadas, a avaliação da performance da ANN desenvolvida é separada em três testes com variação na utilização das técnicas, sendo as variações: estrutura básica sem sobreposição de dados e antecipação de alvos, utilização de sobreposição de dados e por fim a utilização de sobreposição em conjunto com antecipação de alvos. Para cada uma das combinações de técnicas é avaliada a performance na classificação antecipada de eventos epiléticos no conjunto de testes com cada um dos grupos de treinamento evidenciados na Tabela 4.

Ao aplicar todas as técnicas anteriormente descritas não se obtiveram predições antecipadas como pretendido, porém a ANN LSTM conseguiu classificar os eventos epiléticos em tempo de processamento durante os testes. Portanto é avaliada a predição correta a cada segundo durante a ocorrência de janelas de eventos epiléticos a cada predição, isto é, é avaliado a cada segundo (quando é avaliado todo um lote e gerada uma saída) se a predição de um ataque epilético condiz com o alvo daquele lote de teste.

4.1 AVALIAÇÃO DA PERFORMANCE E PREDIÇÕES DA REDE NEURAL

A ANN LSTM utilizada no presente trabalho possui diversos parâmetros variáveis, sendo um desses o número de épocas de treinamento, parâmetro o qual define quantas vezes cada conjunto de dados será processado pela ANN.

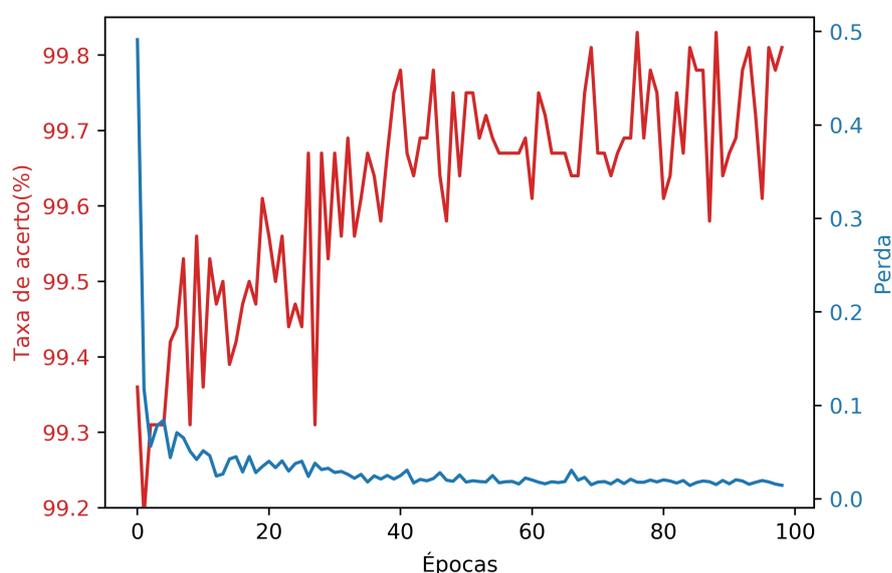
Foi observado que a performance da ANN é afetada pelo número de épocas utilizadas conforme o aumento desse parâmetro. De forma a sumarizar os resultados obtidos, a Tabela 7 relaciona o número de épocas de treinamento com a taxa de acerto e perda (erro de predição, ou o quão distante a classificação categórica está do alvo categórico dos dados de treinamento) acumuladas para a estrutura mais básica de ANN utilizada no presente trabalho – ANN demonstrada na Figura 18 sem aplicação de sobreposição de dados ou antecipação de valores alvo. Os dados do grupo de treinamento 1 foram escolhidos aleatoriamente para este teste.

Tabela 7 – Performance da ANN conforme o número de épocas de treinamento utilizadas. Testes feitos com estrutura básica da ANN e grupo de treinamento 1.

Número de épocas	Taxa de acerto (%)	Perda
10	99.5	0.04
15	99.5	0.04
30	99.6	0.02
60	99.6	0.02

Considerando-se os resultados da Tabela 7, verificou-se que a performance da ANN possui relação direta com a taxa de acerto e mais fortemente com a perda, entretanto essa relação não é linear. A taxa de acerto aumenta muito pouco, variando 0,1%. Já a perda até 30 épocas diminui significativamente conforme o número de épocas, entretanto ao dobrar para 60 épocas a melhoria da perda não segue o padrão anterior, apresentando variação não perceptível, enquanto que ao dobrar de 15 para 30 épocas a diminuição da perda foi de 50%. Dados esses resultados, e considerando que quanto maior o número de épocas, maior o tempo necessário para treinamento da rede, foi escolhido o treinamento com 30 épocas. De forma a melhor ilustrar a comportamento da perda e da taxa de acerto, a Figura 19 apresenta a variação de tais valores ao se variar o número de épocas de 1 a 100.

Figura 19 – Variação da taxa de acerto e da perda da ANN conforme o número de épocas.



As variações abruptas observadas na taxa de acerto são devidas ao processamento de seqüências de sinais com ocorrência de ataques epiléticos. Visto que em quase na totalidade do tempo os indivíduos analisados não apresentavam eventos epiléticos, a ANN aprendeu a classificar muito melhor os eventos inter-ictais, fazendo com que haja variações abruptas na taxa de acerto ao se deparar com segmentos ictais ou pré-ictais, mas com melhora constante na taxa de acerto média.

Uma vez avaliada a performance da rede, são avaliados os resultados de detecção de eventos epiléticos obtidos. Os resultados obtidos com a ANN LSTM desenvolvida não apresentaram em nenhum dos testes a detecção de eventos epiléticos antecipados com padrões consistentes entre arquivos, ou sem a presença de diversas outras detecções semelhantes precedendo a suposta detecção antecipada com diversos períodos de adiantamento, sendo considerada para esta análise a métrica de detecção estabelecida no período de 5 a 60 segundos anterior a um evento epilético, isto é, o período considerado como pré-ictal. De forma a analisar brevemente a aplicação de diferentes métricas, expandindo a janela de análise de eventos epiléticos antecipados para períodos ainda maiores, é mostrado na Tabela 8 uma comparação do percentual de eventos epiléticos detectados antecipadamente com todas técnicas propostas anteriormente, ao se variar a janela de tempo para análise de detecção de eventos epiléticos, indo dos 60 segundos da métrica original até 240 segundos, em passos de 60 segundos.

Tabela 8 – Percentual de detecção antecipada de eventos epiléticos considerando todas as técnicas propostas e variando o tamanho do período pré-ictal. Resultados obtidos para cada grupo de pacientes e para todo o conjunto de grupos.

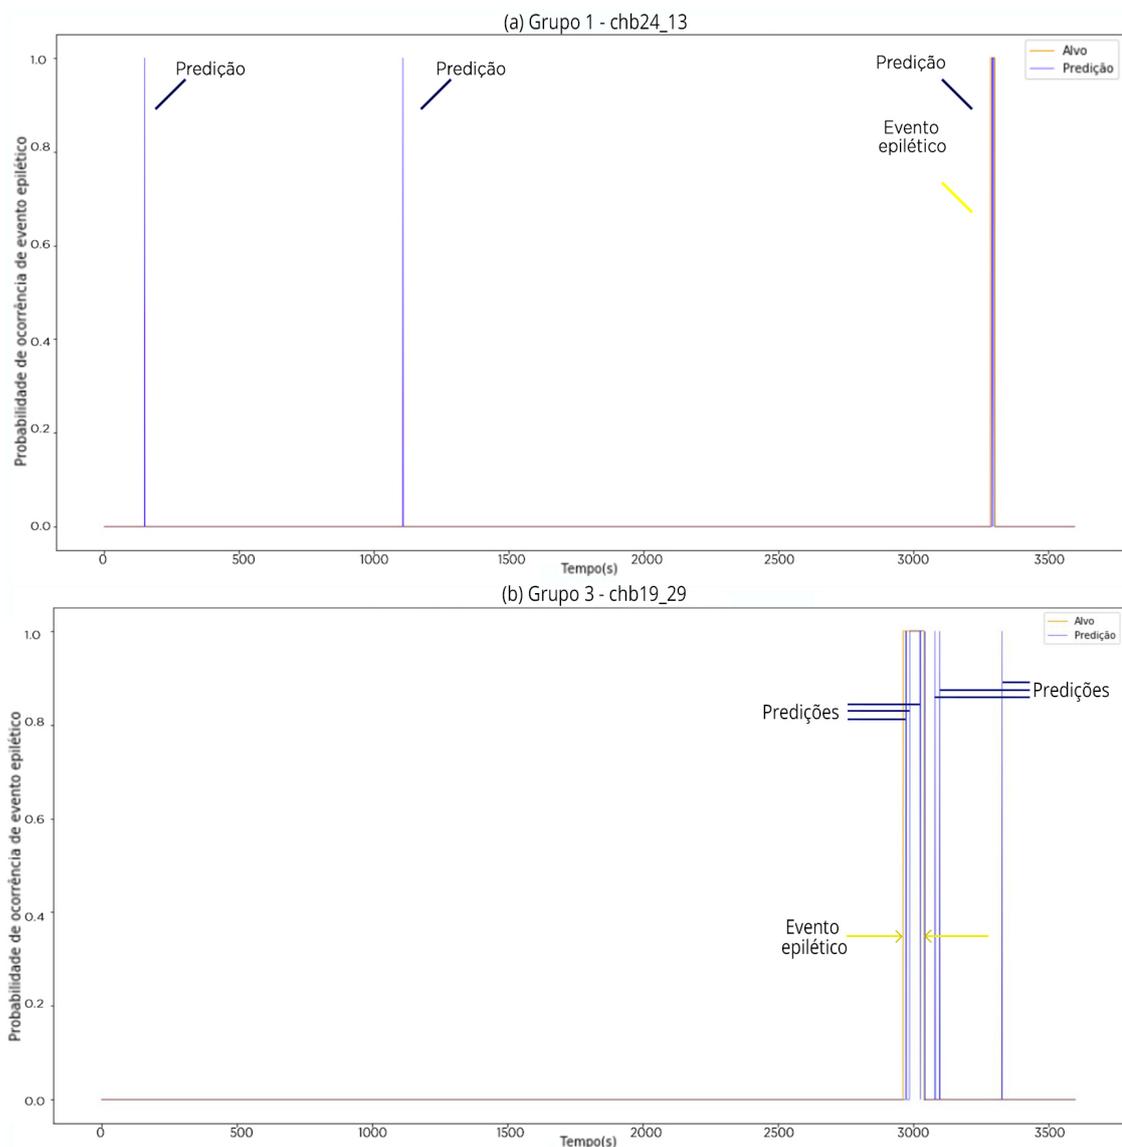
Período pré-ictal (s)	Detecções antecipadas Grupo 1 (%)	Detecções antecipada Grupo 2 (%)	Detecções antecipadas Grupo 3 (%)	Detecções antecipadas Grupo 4 (%)	Detecções antecipadas de eventos epiléticos Total para o período (%)
5 - 60	3.12	0.00	8.33	5.00	3.33
5 - 120	9.37	0.00	8.33	5.00	5.00
5 - 180	9.37	0.00	8.33	5.00	5.00
5 - 240	9.37	0.00	8.33	7.5	5.83

Conforme observado na Tabela 8, o percentual de detecção de eventos epiléticos antecipados é muito pequeno mesmo que a métrica utilizada para o tamanho da janela de detecção seja aumentada em até quatro vezes. O melhor resultado individual, sendo este o grupo 1 com janelas de detecção de limite superior variando de 120 a 240 segundos, alcançou no máximo 9.37% das detecções esperadas. Logo é possível concluir que a análise da capacidade da ANN de detectar antecipadamente eventos epiléticos não está sendo fortemente afetada pela métrica de detecção estabelecida.

Embora a detecção antecipada de eventos epiléticos não tenha atingido resultados significativos através dos testes, as predições obtidas demonstraram que a estrutura LSTM atuou como um classificador, analisando sequências de dados e predizendo para um conjunto de testes os períodos precisos de ocorrência de eventos epiléticos. Exemplos de predição sem antecipação podem ser vistos na Figura 20.

Na Figura 20a, proveniente do grupo 1 de pacientes, é observada a predição correta em praticamente toda janela de ocorrência do evento epilético à direita da figura. Mais no início da mesma figura também pode-se observar predições errôneas, essas servem a título de exemplificação de como poderiam ser os impulsos esperados nas predições antecipadas, caso essas tivessem ocorrido. A Figura 20b demonstra que o mesmo resultado é observado em outros grupos de treinamento e teste, sendo este um exemplo do grupo 3, também apresentando falsos positivos, ao exemplo da Figura 20a. Em ambas figuras é evidenciada a precisão da ANN em classificar os eventos epiléticos, mesmo que hajam pequenas seções dentro da janela do evento em que a classificação oscile.

Figura 20 – Exemplos de predições sem antecipação, ambos arquivos analisados apresentam eventos epiléticos no final dos mesmos. Apesar de não classificarem com antecipação, as predições indicam corretamente a ocorrência de eventos epiléticos. Presença de falsos positivos: (a) no início do arquivo pertencente ao grupo 1 e (b) no final do arquivo pertencente ao grupo 3, logo após o evento epilético.



Os resultados demonstram que as técnicas discutidas no presente trabalho não foram suficientes para antecipação das predições, considerando-se o período pré-ictal estipulado entre 5 e 60 segundos, mas que de fato geraram predições corretas, permitindo à rede assimilar padrões temporais de EEG e classificar a ocorrência de ataques epiléticos na presença de tais padrões.

Ao comparar os resultados com trabalhos relatados no Capítulo 2, Seção 2.3, evidencia-se que apesar de no presente trabalho se fazer uso de semelhantes segmentações de faixas de frequências e utilização de características temporais e espectrais, tal qual nos trabalhos relatados, o resultado esperado não foi obtido, observando-se o máximo percentual de detecção de eventos epiléticos de 3,33% conforme a Tabela 8. É importante considerar para tal comparação que se utilizou no presente desenvolvimento uma base de dados extensa e combinações de dados de diferentes pacientes, com a intenção de generalizar tanto quanto possível os cenários possíveis de serem observados. Idealmente esta combinação de fatores faria a ANN apreender a generalização de segmentos pré-ictais independentemente de possíveis fatores fisiológicos ou psíquicos não relacionados aos eventos epiléticos, porém o que possivelmente ocorreu foi a dificuldade de treinamento de tantos cenários e para tantos pacientes com padrões de EEG distintos.

O trabalho de (AMMAR; SENOUCI, 2016), por utilizar a mesma base dados que neste desenvolvimento, é o trabalho com características mais próximas para comparação. As características temporais e espectrais possuem semelhanças, embora os resultados finais tenham grande divergência, tendo o trabalho citado alcançado 95% de classificações corretas. Os autores utilizaram de somente um canal de EEG, o qual não foi utilizado neste desenvolvimento, porém foram selecionados somente 3 pacientes, o que contrasta com o presente trabalho, onde, apesar de se utilizar 4 canais de EEG, foram selecionados 10 pacientes distintos para análise, totalizando 5 vezes mais dados, considerando o número de dados para os pacientes escolhidos em cada trabalho. Portanto novamente se considera a hipótese da ANN do trabalho referido ter sido submetida a um número limitado de cenários, reduzindo a quantidade de padrões a serem aprendidos, ou ainda há a possibilidade de que a técnica de ELM de fato tenha sido mais apropriada para este cenário.

Dada a discussão sobre a ausência de predições antecipadas, de forma a explorar os resultados obtidos pela ANN LSTM com os diferentes tipos de estruturas propostas no presente trabalho, é avaliado a seguir somente o desempenho da rede para classificação de regiões ictais, isto é, a predição não antecipada de eventos epiléticos.

4.2 TREINAMENTO COM ESTRUTURA BÁSICA

Utilizando-se da ANN apresentada na Figura 18 sem aplicação de sobreposição de dados ou antecipação de valores alvo, foram obtidas as matrizes de confusão mostradas na

Figura 21, relacionando as *sensitivities* e *specificities* na classificação de eventos epiléticos para cada um dos quatro grupos de treinamento, isto é, determinação de períodos ictais.

Os resultados apresentados para a estrutura básica evidenciam que a *specificity* é muito alta, variando de 99,0% para o grupo 3 até 100% para os grupos 2 e 4, como era esperado devido ao desbalanceamento de regiões, as quais são predominantemente inter-ictais. A *sensitivity* no entanto apresentou uma baixa performance, atingindo no máximo 45,5% para o grupo 3.

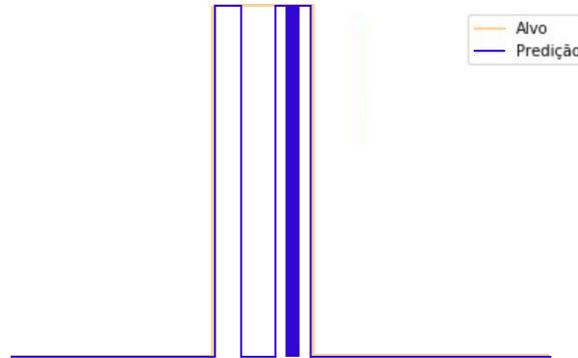
Figura 21 – Matrizes de confusão da determinação de períodos ictais para todos grupos de treinamento utilizando estrutura de treinamento básica.

		(a) Grupo 1			(b) Grupo 2		
Predição	Inter ictal	28468 98.8%	212 0.74%	28680 99.3%	20759 96.1%	841 3.89%	21600 96.1%
	Ictal	19 0.07%	101 0.35%	120 84.2%	0 0.00%	0 0.00%	0 0.00%
		28487 99.9%	313 32.3%	28800 99.2%	20759 100%	841 0.00%	21600 96.1%
		0.07%	67.7%	0.80%	0.00%	100%	3.89%
		Inter ictal	Ictal		Inter ictal	Ictal	
			Alvo			Alvo	
		(c) Grupo 3			(d) Grupo 4		
Predição	Inter ictal	10453 99.8%	134 1.24%	10587 98.7%	21504 99.6%	94 0.44%	21598 99.6%
	Ictal	101 0.94%	112 1.04%	213 52.6%	2 0.01%	0 0.00%	2 0.00%
		10554 99.0%	246 45.5%	10800 97.8%	21506 100%	94 0.00%	21600 99.6%
		0.96%	54.47%	2.18%	0.01%	100%	0.44%
		Inter ictal	Ictal		Inter ictal	Ictal	
			Alvo			Alvo	

Os resultados obtidos demonstram que a classificação de períodos ictais não obteve uma boa taxa de verdadeiros positivos, apesar de haverem detecções parciais dos períodos para quase todos grupos, com exceção dos grupos 2 e 4 que não apresentaram nenhum acerto, entretanto deve-se ponderar que houveram detecções dentro de janelas de eventos

ictais no formato de picos ou janelas menores. Um exemplo das detecções pode ser visto na Figura 22, a qual mostra um exemplo de detecção para o grupo 1.

Figura 22 – Picos de detecção dentro de uma janela de ocorrência de um evento epilético. Trechos sem detecção se refletem na *sensitivity* da rede.



São sumarizados na Tabela 9 os resultados obtidos com a estrutura básica, envolvendo a taxa de acerto da ANN e parâmetros apresentados nas matrizes de confusão.

Tabela 9 – Resultados obtidos com estrutura básica de treinamento.

Grupo de treinamento	Taxa de acerto da ANN (%)	<i>Sensitivity</i> (%)	<i>Specificity</i> (%)
1	99.6	32.3	99.9
2	93.2	0.00	100
3	97.5	45.5	99.0
4	100	0.00	100

Avaliando a taxa de acerto é possível verificar que esta não necessariamente condiz com a *specificity* e *sensitivity* verificada no conjunto de testes. Isso pode ser devido a parte do treinamento ser feita com dados de mais de um paciente e o teste envolver pacientes que tiveram participação parcial no treinamento pelo fato de serem usados somente arquivos onde foram verificados eventos epiléticos. Relacionando os resultados de *sensitivities* e *specificities* obtidos com a divisão de grupos de treinamento, verifica-se que tal divisão demonstrou que não foi possível obter uma generalização satisfatória para classificação de períodos ictais ou pré-ictais. Isso se reflete claramente na ausência de predições verdadeiro positivas nos grupos 2 e 4. Um aspecto importante quanto aos grupos 2 e 4 apresentarem os piores resultados possíveis é visto na Tabela 4, pois nessa tabela é possível observar que estes grupos de pacientes são os que apresentam maior discrepância no número de eventos epiléticos e, portanto, possuem maior probabilidade de serem quadros epiléticos com padrões e intensidades distintas. Portanto é possível afirmar que há indícios de que as estruturas propostas apresentam resultados dependentes dos pacientes, ou de padrões distintos de EEG, e que a performance da ANN é afetada negativamente para pacientes com quantidades de incidências de eventos epiléticos mais discrepantes.

Ao comparar os resultados com trabalhos como o de (GUPTA; SINGH; KARLEKAR, 2018), o qual apresentou *sensitivity* em torno de 98% na classificação de regiões ictal, inter-ictal e pré-ictal com classificador SVM, verifica-se que os resultados obtidos com a presente ANN LSTM, utilizando-se da estrutura básica anteriormente descrita, são muito menos satisfatórios por chegarem ao máximo de 45,5% de *sensitivity*. Entretanto deve-se ponderar que, como citado por (GUPTA; SINGH; KARLEKAR, 2018), a base de dados de tal trabalho era limitada, sendo cerca de 30 vezes menor em extensão temporal de gravações em relação à base de dados aqui utilizada, possuindo 3,28 horas de dados contra 101 horas dos arquivos utilizados no presente trabalho. Isso pode eventualmente causar sobre-ajuste por se tratar da análise de dados com menor probabilidade de evidenciarem um número maior de cenários onde uma ANN poderia classificar erroneamente um segmento de dados, ou um cenário de evento epilético que mostrasse características diferentes dos demais eventos epiléticos observados.

4.3 TREINAMENTO COM SOBREPOSIÇÃO DE DADOS

Através da sobreposição dos dados conforme indicado no exemplo da Figura 15, foram obtidos os resultados dispostos na Tabela 10:

Tabela 10 – Resultados obtidos com técnica de sobreposição de dados com janelas deslizantes.

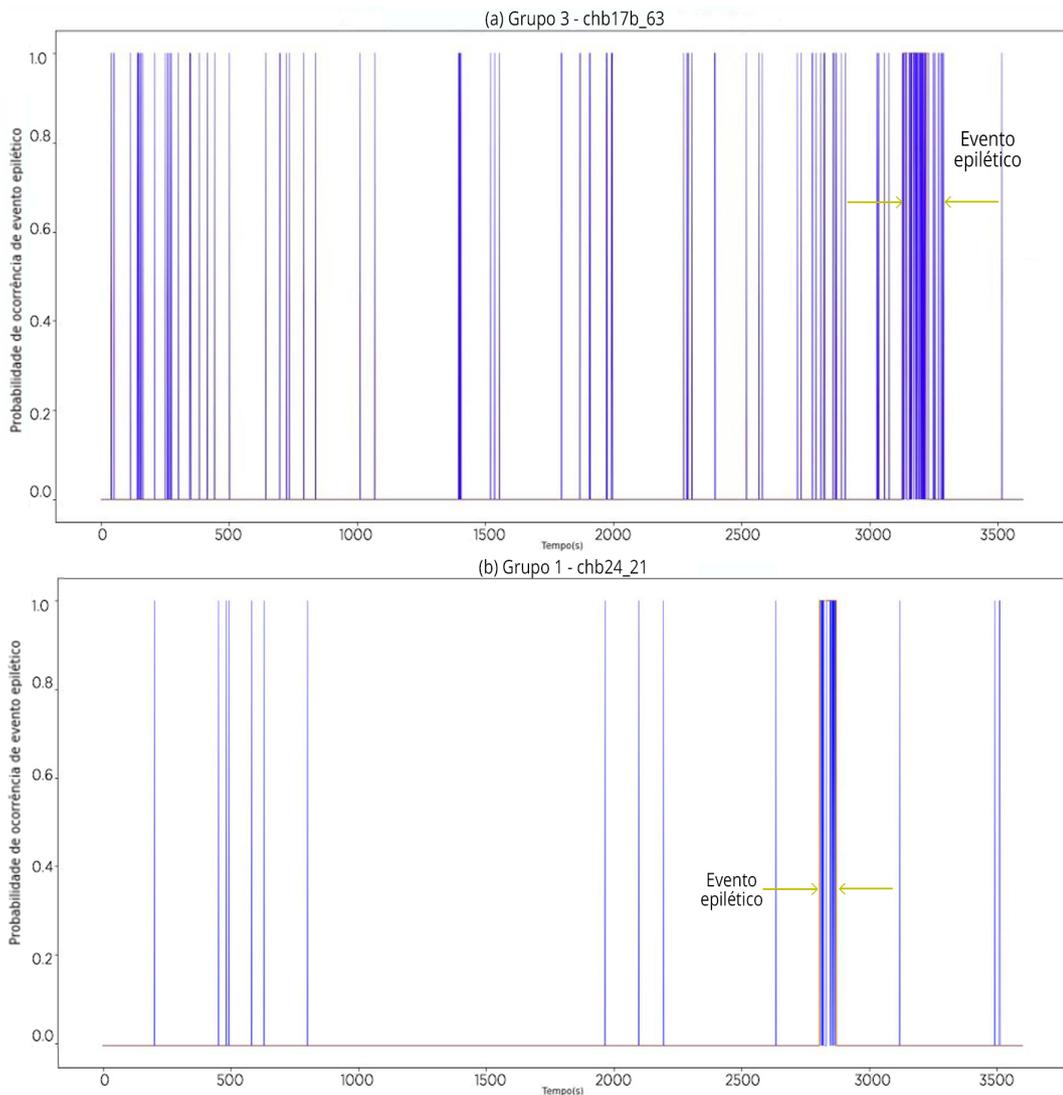
Grupo de treinamento	Taxa de acerto da ANN (%)	<i>Sensitivity</i> (%)	<i>Specificity</i> (%)
1	99.5	47.0	99.7
2	93.2	0.00	100
3	98.1	61.3	97.3
4	100	0.00	98.2

Ao analisar os resultados expostos na Tabela 10, verifica-se que a *sensitivity* da ANN aumentou com a utilização da técnica de sobreposição de dados em relação à estrutura básica, o que evidencia que esta técnica atenua a ocorrência de falsos negativos. Entretanto a taxa de falsos positivos também aumenta demasiadamente, conforme visto na Figura 23, a qual demonstra os resultados para os grupo 3 e 1.

A Figura 23 representa um registro de ocorrência de eventos epiléticos onde só há um evento epilético em cada arquivo. Na Figura 23a, referente ao grupo 3, o evento está localizado entre 3000 e 3500 segundos, sobreposto por diversos picos de detecção da ANN, sendo inclusive difícil distinguir o evento dos picos de detecção devido à alternância entre classificações corretas e errôneas. Portanto é possível observar que a ANN corretamente identifica esse segmento gerando diversos picos, isto é, gerando diversas classificações nesse segmento como trechos de sinais ictais. Esse comportamento se reflete em uma *sensitivity* mais elevada em comparação com a estrutura básica de treinamento. A Figura 23b expõe

o resultado da mesma técnica de sobreposição mas para o grupo 1, contendo também somente um único evento epilético entre 2500 e 3000 segundos neste arquivo específico exibido. É possível notar que há a correta classificação de tal evento através da geração de diversos picos de detecção com grande concentração no mesmo intervalo de tempo do evento epilético, o que juntamente com as diversas detecções falso positivas ao longo do arquivo configuram um comportamento tal qual visto na Figura 23a, proveniente da técnica de sobreposição de dados.

Figura 23 – Exemplo dos resultados obtidos com sobreposição de dados para arquivos do grupo 1 e 3. Há uma ocorrência de evento epilético ao final de cada arquivo, onde se encontram muitos picos de detecção. A *sensitivity* apresenta bons resultados em detrimento da *specificity*, resultado evidenciado por muitos falsos positivos. Os eventos epiléticos são demarcados por setas para melhor identificação. (a) arquivo do grupo 3, cujo evento epilético se encontra entre 3000 e 3500 segundos, encoberto por diversos picos de detecção. (b) arquivo do grupo 1, com clara classificação do período ictal entre 2500 e 3000 segundos.



Além do teste realizado com a metodologia anteriormente descrita, também foi realizado um breve teste para comparação com um valor de janela e passo de sobreposição diferentes dos propostos originalmente. Ao invés de janelas de sobreposição de 1 segundo com passos de meio segundo, foram divididos pela metade e também dobrados os parâmetros utilizados na sobreposição de dados, ou seja, foram aplicadas janelas de 0,5 e 2 segundos, e passos de 0,25 e 1 segundo. Utilizando somente o grupo de treinamento 1, se obtiveram os resultados exibidos na Tabela 11:

Tabela 11 – Comparação de resultados resultantes da variação do tamanho da janela e do passo de sobreposição aplicados aos dados de treinamento. Teste realizado com grupo de pacientes 1.

Tamanho da janela (s)	Tamanho do passo (s)	<i>Sensitivity</i> (%)	<i>Specificity</i> (%)
0.50	0.25	32.6	99.9
1.00	0.50	47.0	99.7
2.00	1.00	34.8	99.9

Fica evidente que, ao aumentar ou diminuir a janela e passo de sobreposição de dados de treinamento, a *sensitivity* da ANN piora consideravelmente. Isso evidencia que os parâmetros de sobreposição de dados possuem um valor ótimo, ao invés de tendências de melhoria diretamente proporcional ao tamanho desses parâmetros. Portanto pode-se afirmar que os parâmetros utilizados para sobreposição de dados na presente metodologia estão corretamente dimensionados.

Os resultados dos testes executados com a técnica de sobreposição de dados demonstram que, além da melhora em classificações e piora no número de falsos positivos, que os grupos 2 e 4 continuam a não classificar corretamente nenhum segmento ictal, reforçando uma característica da ANN desenvolvida de ter performance dependente dos pacientes e seus padrões de EEG, apresentando melhores resultados para determinados grupos de pacientes.

Apesar de não terem sido estudados no Capítulo 2, Seção 2.3, trabalhos que envolvessem sobreposição de dados, ainda sim foi visto que para (DADGAR-KIANI; ALKAN; SHAMELI, 2016) houveram metodologias para melhora da *sensitivity* com a desvantagem da piora do número de falsos positivos, evidenciando a possibilidade de certas técnicas não conseguirem melhorar a classificação de regiões de sinais temporais sem também aumentarem significativamente a quantidade de classificação errônea de demais regiões. Portanto, de forma mais específica, caso uma aplicação de RNN LSTM com sinais de EEG deseje melhorar a *sensitivity* e possa tolerar pioras na taxa de falsos positivos, a sobreposição de dados de treinamento pode vir a ser uma técnica eficaz.

4.4 TREINAMENTO COM ANTECIPAÇÃO DE ALVOS

A aplicação de antecipação de alvos resultou nas taxas de acerto, *sensitivity* e *specificities* resumidas na Tabela 12:

Tabela 12 – Resultados obtidos com técnica de antecipação de alvos no conjunto de treinamento.

Grupo de treinamento	Taxa de acerto da ANN (%)	<i>Sensitivity</i> (%)	<i>Specificity</i> (%)
1	99.5	33.9	99.7
2	92.9	0.00	100
3	97.6	40.2	99.1
4	100	0.00	99.8

Apesar de os alvos de treinamento terem sido antecipados, antecedendo em 5 segundos um evento epilético, com a marcação do valor “1” nos alvos, a *sensitivity* melhorou em 1,60% para o grupo 1 e piorou em 5,30% para o grupo 3, ou seja, não houve uma melhora consistente nos resultados. Fora isso a taxa de acerto da ANN e a *specificity* pioraram para praticamente todos os grupos de treinamento. Este resultado demonstra que para a estrutura de ANN e configurações propostas no presente trabalho a antecipação de alvos tende a evidenciar uma pequena piora nos resultados, ou no melhor caso um pequeno aumento de *sensitivity*.

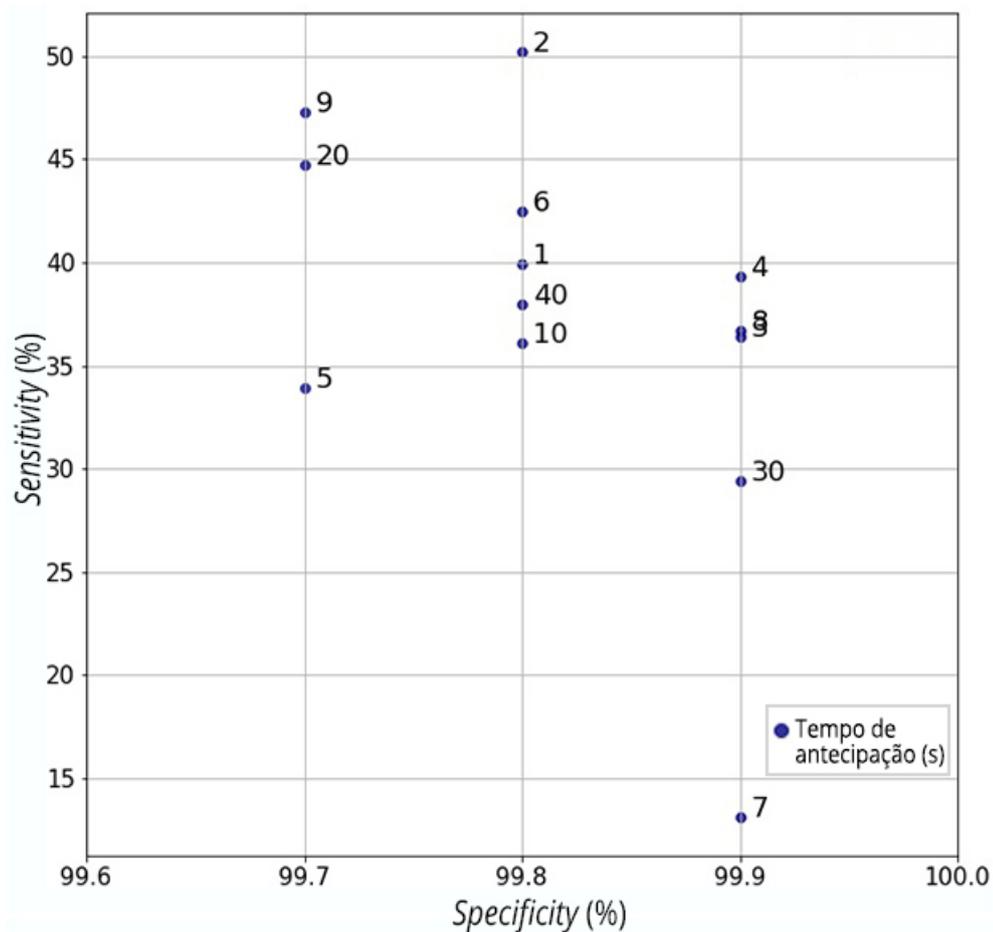
De forma a explorar brevemente os resultados para demais valores de antecipação de alvos, é exibido na Tabela 13 os valores de *sensitivity* e *specificity* obtidos para o grupo de pacientes 1 ao se variar o tempo de antecipação de alvos dentre diversos valores indo de 1 a 40 segundos.

Tabela 13 – Resultados obtidos ao se variar o tempo de antecipação de alvos de treinamento para o grupo de pacientes 1.

Tempo de antecipação (s)	<i>Sensitivity</i> (%)	<i>Specificity</i> (%)
1	39.9	99.8
2	50.2	99.8
3	36.4	99.9
4	39.3	99.9
5	33.9	99.7
6	42.5	99.8
7	13.1	99.9
8	36.7	99.9
9	47.3	99.7
10	36.1	99.8
20	44.7	99.7
30	29.4	99.9
40	38.0	99.8

Os resultados mostram que não há uma tendência de variação consistente na performance das predições conforme se varia o tempo de antecipação, pois, por exemplo, o melhor resultado de *sensitivity* foi obtido para uma antecipação de alvos de 2 segundos, enquanto que o pior resultado foi para a antecipação de 7 segundos, entretanto o segundo melhor resultado ocorre para antecipação de 9 segundos. Para melhor ilustrar a aleatoriedade dos resultados, é exibido na Figura 24 uma representação visual dos dados da Tabela 13.

Figura 24 – Representação visual dos resultados obtidos com variação do tempo de antecipação de alvos de treinamento para o grupo de pacientes 1.



Na Figura 24, ao se observar o posicionamento espacial dos resultados de um tempo de antecipação com o resultado do tempo de antecipação seguinte, é possível ver mais claramente que não há uma tendência consistente de variação da performance das predições.

É interessante notar que o tempo de antecipação de alvos de treinamento arbitrariamente escolhido na presente metodologia não foi o melhor, e que este valor também não aparenta ter um máximo local. Conforme abordado no Capítulo 3, Seção 3.3.4, o trabalho de (JAIN *et al.*, 2015) conseguiu antecipar predições de movimentos faciais, monitorados com uma câmera, ao utilizar antecipação de dados. Entretanto, apesar da presente arquitetura de ANN diferir da arquitetura proposta por (JAIN *et al.*, 2015), o

princípio do treinamento com antecipação de dados é o mesmo. Unindo o aspecto de terem sido observados resultados aleatórios ao se variar o tempo de antecipação de alvos, com o fato da inabilidade de predição antecipada para a presente metodologia, logo se sugere a hipótese da diferença de resultados poder estar relacionada com a natureza dos dados, isto é, há a possibilidade de haver uma característica inerente aos padrões de sinais de EEG que torne ineficiente a antecipação de alvos de treinamento no objetivo de antecipar as predições.

Para a ANN e metodologia propostas, a falha em obter melhores resultados com demarcação explícita de valores alvos em regiões nas quais foram definidas como pré-ictais (período anterior a 5 segundos do começo de uma região ictal) sugere que não foi possível extrair representações matemáticas com correlação suficientemente fortes com regiões pré-ictais, e nem com regiões ictais como demonstra a Tabela 12, apesar de que com diferentes tempos de antecipação, diferentes do tempo proposto na presente metodologia, foi observada a possibilidade de ser obter correlações razoáveis com períodos ictais, conforme a Tabela 13.

4.5 TREINAMENTO COM SOBREPÓSICÃO DE DADOS E ANTECIPAÇÃO DE ALVOS

A última técnica proposta aplica a sobreposição das entradas e alvos do conjunto de treinamento e antecipa os alvos do mesmo conjunto. Essa combinação de técnicas resultou nas taxas de acertos, *sensitivity* e *specificities* resumidas na Tabela 14:

Tabela 14 – Resultados obtidos com técnica de sobreposição de dados e antecipação de alvos no conjunto de treinamento.

Grupo de treinamento	Taxa de acerto da ANN (%)	<i>Sensitivity</i> (%)	<i>Specificity</i> (%)
1	99.6	49.2	99.2
2	93.1	0.00	100
3	96.9	29.3	99.6
4	100	0.00	100

Assim como nas técnicas de antecipação de alvos sem a sobreposição de dados, não houve um aumento consistente da *sensitivity*. Apesar da melhoria da *sensitivity* de 16,9% para o grupo 1, houve uma piora de 16,3% para o grupo 3, caracterizando forte dependência da performance com o paciente analisado.

Apesar da sobreposição de dados resultar em *sensitivity* maiores para os grupos 1 e 3, lembrando que para os demais grupos as *sensitivities* foram nulas, os resultados seguiram o padrão observado na antecipação de alvos, obtendo-se, em comparação com a estrutura básica, *sensitivities* melhores para o grupo 1 e piores para o grupo 3. Isso mostra que para a estrutura de ANN e técnicas propostas no presente trabalho, a utilização de

antecipação de alvos além de não trazer bons resultados consistentes para a *sensitivity* de predições, também apresenta os mesmos comportamentos quando utilizada em conjunto com outras técnicas.

5 CONCLUSÕES

Ao se analisar os resultados obtidos, é possível afirmar que com a metodologia adotada não é possível determinar períodos pré-ictais em sinais de EEG com redes LSTM. Para a determinação antecipada de eventos epiléticos podem ser necessárias mais características, diferentes combinações dessas ou diferentes técnicas de manipulação dos dados de treinamento.

A ANN LSTM apresentou elevadas taxas de acerto e *specificity*, porém *sensibilities* medianas. Os resultados de *sensitivity* foram medianos somente para metade das combinações de grupos de pacientes e técnicas de pré-processamento de dados de treinamento, sendo que para outra metade dos grupos de treinamento a *sensitivity* obtida foi nula, demonstrando forte dependência da técnica proposta com o paciente e seus padrões de EEG. A alta taxa de acerto verificada em todos testes se mostrou coerente somente com a detecção de regiões ictais, e não pré-ictais, evidenciando que as técnicas de pré-processamento ou configurações da topologia da ANN LSTM não foram suficientemente ajustadas para categorizar as sequências temporais pré-ictais desejadas.

Apesar da detecção de eventos epiléticos não ter ocorrido de forma antecipada, a ANN conseguiu apreender padrões temporais para predição categórica de regiões ictais, gerando picos ou janelas de detecção na ocorrência de eventos epiléticos. Isso demonstra que a topologia LSTM de RNNs apresenta aprendizado e capacidade de memória e correlação de dados para longas sequências temporais, em específico na aplicação atual para sinais de EEG.

Embora a abundância de dados aumente as chances de correto aprendizado da rede, também foi verificado que o excesso de registros de períodos sem eventos epiléticos (períodos inter-ictais), configurando um desbalanceamento de dados, favoreceu a tendência a melhor classificação de períodos inter-ictais em detrimento dos períodos ictais e pré-ictais. Isso se mostrou evidente na evolução do erro de treinamento acumulado ao se deparar com dados com vários eventos epiléticos, aumentando significativamente o erro ao primeiro contato mas diminuindo significativamente com a execução de mais épocas.

Avaliando as técnicas de tratamento de dados, a redução de canais para menos de 25% dos canais selecionados demonstrou resultados positivos na classificação de sequências temporais, embora testes extensivos com diferentes combinações dos 18 canais inicialmente selecionados pudessem avaliar melhor a correlação entre composição de canais e classificação de regiões ictais e pré-ictais.

6 PROPOSTAS PARA TRABALHOS FUTUROS

Em trabalhos futuros a natural prioridade é a obtenção de antecipação nas predições. Para tal é sugerido a experimentação de técnicas de reestruturação dos dados de treinamento, como diferentes sobreposições de dados com janelas de tamanhos variáveis. Outra sugestão é a modificação da função de custo para treinamento da rede, dando maior peso a entradas cujo alvo seja a ocorrência de um evento epilético, ou estado pré-ictal caso sejam deslocados os alvos assim como feito no presente trabalho.

A seleção de pacientes da base atual foi dada por eliminação conforme os canais presentes e posteriormente feita uma filtragem que resultou em grupos estatísticos de teste, portanto a validação com mais pacientes, assim como a validação com outras bases de dados de eventos epiléticos é importante para garantir da generalização da ANN desenvolvida.

Quanto às características utilizadas na ANN, se sugere a experimentação da combinação de diferentes características, utilizando Análise Discriminante Multivariada, de forma a encontrar características resultantes que possuam maior correlação os períodos pré-ictais. A combinação de diferentes características também pode resultar numa redução de dimensionalidade e eventual eliminação de características redundantes para o treinamento.

Além disso, é essencial a elaboração de um Projeto de Experimentos desde o princípio da continuação deste trabalho para possibilitar a caracterização mais coerente dos fatores controláveis, das variáveis de resposta desejadas, assim como, de uma validação estatística robusta.

REFERÊNCIAS BIBLIOGRÁFICAS

- ALBUQUERQUE, M. de; CENDES, F. Estado de mal epiléptico em adultos: revisão e proposta de protocolo. **Journal of Epilepsy and Clinical Neurophysiology**, Porto Alegre, v. 17, n. 4, p. 164 – 175, jan. 2011.
- ALLAKA, S. K. *et al.* Machine learning for seizure prediction: A revamped approach. In: COMPUTING, C. 2015 International Conference on Advances in; (ICACCI), . I. (Ed.). Kochi: IEEE, 2015. p. 1159–1164.
- ALOTAIBY, T. *et al.* A review of channel selection algorithms for eeg signal processing. **EURASIP Journal on Advances in Signal Processing**, [S.l.], v. 2015, n. 1, p. 66, Aug. 2015.
- AMMAR, S.; SENOUCI, M. Seizure detection with single-channel eeg using extreme learning machine. In: SCIENCES, . 17th International Conference on; CONTROL, T. of A.; (STA), . C. E. (Ed.). Sousse, Tunisia: IEEE, 2016. p. 776–779.
- BENGIO, Y.; SIMARD, P.; FRASCONI, P. Learning long-term dependencies with gradient descent is difficult. **IEEE Transactions on Neural Networks**, [S.l.], v. 5, n. 2, p. 157–166, Mar. 1994.
- BIRJANDTALAB, J. *et al.* Automated seizure detection using limited-channel eeg and non-linear dimension reduction. **Computers in Biology and Medicine**, [S.l.], v. 82, n. 1, p. 49–58, Jan. 2017.
- BISHOP, C. M. **Neural Networks for Pattern Recognition**. New York, NY, USA: Oxford University Press, Inc., 1995.
- BROMFIELD, E. B.; CAVAZOS, J. E.; SIRVEN, J. I. **Introduction to Epilepsy**. [S.l.]: American Epilepsy Society, 2006. <<https://www.ncbi.nlm.nih.gov/books/NBK2508>>. Acesso em: 02 maio 2018.
- BUSCH, P.; HEINONEN, T.; LAHTI, P. Heisenberg’s uncertainty principle. **Physics Reports**, [S.l.], n. 452, p. 155–176, Oct. 2007.
- CHANG, N. *et al.* Channel selection for epilepsy seizure prediction method based on machine learning. In: MEDICINE, I. C. of the IEEE Engineering in; SOCIETY, B. (Ed.). San Diego, USA: IEEE, 2012. p. 5162–5165.
- CHELLAPPA, R. *et al.* **Academic Press Library in Signal Processing: Signal Processing Theory and Machine Learning**. Oxford, UK: Elsevier Science, 2013.
- COOK, M. J. *et al.* Prediction of seizure likelihood with a long-term, implanted seizure advisory system in patients with drug-resistant epilepsy: a rst-in-man study. **The Lancet Neurology**, [S.l.], v. 12, n. 6, p. 563–71, Jun. 2013.
- DADGAR-KIANI, E.; ALKAN, C.; SHAMELI, A. **Applying Machine Learning for Human Seizure Prediction**. Stanford, California, 2016. 6 p.
- GANEGEDARA, T. **Stock Market Predictions with LSTM in Python**. 2018. Disponível em: <<https://www.datacamp.com/community/tutorials/lstm-python-stock-market>>. Acesso em: 28 maio 2018.

GERS, F.; SCHMIDHUBER, J. Recurrent nets that time and count. In: CHALLENGES, P. of the IEEE-INNS-ENNS International Joint Conference on N. N. I. . N. C. N.; MILLENNIUM, P. for the N. (Ed.). Como, Italy: IEEE, 2000. p. 189 – 194.

GOLDBERGER, A. L. *et al.* Physiobank, physiotoolkit, and physionet: Components of a new research resource for complex physiologic signals. **Circulation**, [S.l.], v. 101, n. 23, p. 215–220, Jun. 2000.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. [S.l.]: MIT Press, 2016. Disponível em: <<http://www.deeplearningbook.org>>. Acesso em: 27 maio 2018.

GREENE, B. *et al.* Automated single channel seizure detection in the neonate. In: MEDICINE, A. I. C. of the IEEE Engineering in; MEDICINE, B. S. I. E. in; SOCIETY, B. (Ed.). Vancouver, Canada: [s.n.], 2008. p. 915–8.

GUPTA, A.; SINGH, P.; KARLEKAR, M. A novel signal modeling approach for classification of seizure and seizure-free eeg signals. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, [S.l.], p. 1–1, Mar. 2018.

GUYON, I. *et al.* **Feature Extraction: Foundations and Applications**. New York: Springer-Verlag New York Inc, 2006.

HAYKIN, S. S. **Neural networks and learning machines**. Upper Saddle River, NJ: Pearson Education, 2009.

HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. **Neural computation**, [S.l.], v. 9, n. 8, p. 1735–80, Nov. 1997.

JAIN, A. *et al.* Recurrent neural networks for driver activity anticipation via sensory-fusion architecture. **CoRR**, [S.l.], v. 1, p. 1–8, Sep. 2015.

JORY, C. *et al.* Safe and sound? a systematic literature review of seizure detection methods for personal use. **Seizure**, [S.l.], v. 36, p. 4 – 15, Nov. 2016.

JUPYTER. **Project Jupyter**. 2018. Disponível em: <<http://jupyter.org/>>. Acesso em: 28 ago 2018.

KERAS. **Keras Documentation**. 2018. Disponível em: <<https://keras.io/>>. Acesso em: 27 set 2018.

KERR, C.; NIXON, A.; ANGALAKUDITI, M. The impact of epilepsy on children and adult patients' lives: Development of a conceptual model from qualitative literature. **Seizure**, [S.l.], v. 20, n. 10, p. 764 – 774, Dec. 2011.

KLEM, G. *et al.* The ten-twenty electrode system of the international federation. the international federation of clinical neurophysiology. **Electroencephalography and clinical neurophysiology**, [S.l.], v. 52, p. 3 – 6, Jan. 1999.

KLONOWSKI, W. From conformons to human brains: an informal overview of nonlinear dynamics and its applications in biomedicine. **Nonlinear Biomed Phys.**, [S.l.], v. 1, n. 5, p. 5, Jul. 2007.

LARMUSEAU, M.; DAMBRE, J. **Epileptic Seizure Prediction Using Deep Learning**. 114 p. Dissertation (Master of Science in Biomedical Engineering) — Ghent University, Ghent, 2016.

- NIEDERMEYER, E.; SILVA, F. H. L. da. **Electroencephalography: Basic Principles, Clinical Applications, and Related Fields**. 6. ed. Baltimore: Williams Williams, 1993.
- NUNEZ, P. L.; SRINIVASAN, R. **Electric fields of the brain: the neurophysics of EEG**. 2. ed. New York: Oxford University Press, 2006.
- OGASAWARA, E. *et al.* Adaptive normalization: A novel data normalization approach for non-stationary time series. In: (IJCNN), T. . I. J. C. on N. N. (Ed.). Barcelona: [s.n.], 2010. p. 1–8.
- PANAYIOTOPOULOS, C. P. **The Epilepsies: Seizures, Syndromes and Management : Based on the Ilae Classifications and Practice Parameter Guidelines**. Oxfordshire, UK: Bladon Medical Publishing,, 2005.
- PERVEN, G.; SO, N. K. Epileptic auras: phenomenology and neurophysiology. **Epileptic Disord**, [S.l.], v. 17, n. 4, p. 349–62, Dec. 2015.
- PHYSIONET. **CHB-MIT Scalp EEG Database**. 2018. Disponível em: <<https://www.physionet.org/pn6/chbmit/>>. Acesso em: 01 jun 2018.
- PHYSIONET. **The WFDB Software Package**. 2018. Disponível em: <<https://www.physionet.org/physiotools/wfdb.shtml>>. Acesso em: 01 jun 2018.
- PYTHON, S. F. **Python**. 2018. Disponível em: <<https://www.python.org/>>. Acesso em: 28 ago 2018.
- SHARBROUGH, F. W. *et al.* Guideline thirteen: Guidelines for standard electrode position nomenclature american electroencephalographic society. **J. Clin. Neurophysiol.**, [S.l.], v. 8, n. 2, Jan. 1991.
- SHETA, A. F.; AHMED, S. E. M.; FARIS, H. A comparison between regression, artificial neural networks and support vector machines for predicting stock market index. **International Journal of Advanced Research in Artificial Intelligence(IJARAI)**, [S.l.], v. 4, n. 7, Apr. 2015.
- SHOEB, A.; GUTTAG, J. Application of machine learning to epileptic seizure detection. In: (ICML) 27th International Conference on M. L. (Ed.). Haifa: MIT Press, 2010. p. 21–24.
- SHORVON, S. D. *et al.* **Oxford textbook of epilepsy and epileptic seizures**. Oxford: Oxford University Press, 2013.
- SIULY, S.; LI, Y.; ZHANG, Y. **EEG signal analysis and classification: techniques and applications**. Melbourne: Springer International Publishing AG, 2016.
- STANDRING, S. **Gray's Anatomia: A base anatômica da prática clínica**. 40. ed. Rio de Janeiro: Elsevier Health Sciences Brazil, 2010.
- SUNDERMEYER, M.; NEY, H.; SCHLÜTER, R. From feedforward to recurrent lstm neural networks for language modeling. **IEEE/ACM Transactions on Audio, Speech, and Language Processing**, [S.l.], v. 23, n. 3, p. 517–529, Mar. 2015.

TENSORFLOW. **Tensorflow**. 2018. Disponível em: <<https://www.tensorflow.org/>>. Acesso em: 27 set 2018.

TORTORA, G. **Corpo Humano: Fundamentos de Anatomia e Fisiologia**. 4. ed. Porto Alegre: Artmed, 2000.

TZALLAS, A. T. *et al.* Automated epileptic seizure detection methods : A review study. In: STEVANOVIC, D. (Ed.). **Epilepsy - Histological, Electroencephalographic and Psychological Aspects**. 1. ed. [S.l.]: InTech, 2012. cap. 4, p. 75–98.

VANDECASTEELE, K. *et al.* Automated epileptic seizure detection based on wearable ecg and ppg in a hospital environment. **Sensors**, [S.l.], v. 17, n. 10, p. 2338, Oct 2017.