



**UNIVERSIDADE
FEDERAL RURAL
DE PERNAMBUCO**

Danielly de Moura Borba Queiroz

Classificação de imagens de textura geradas por Gráficos de Recorrências no problema de pessoas sofrendo ataques epiléticos

Recife

2019

Danielly de Moura Borba Queiroz

**Classificação de imagens de textura geradas por Gráficos
de Recorrências no problema de pessoas sofrendo
ataques epiléticos**

Monografia apresentada ao Curso de Bacharelado em Ciência da Computação da Universidade Federal Rural de Pernambuco, como requisito parcial para obtenção do título de Bacharel em Ciência da Computação.

Universidade Federal Rural de Pernambuco – UFRPE
Departamento de Computação
Curso de Bacharelado em Ciência da Computação

Orientador: Valmir Macário Filho

Recife
2019

Dados Internacionais de Catalogação na Publicação
Universidade Federal Rural de Pernambuco
Sistema Integrado de Bibliotecas
Gerada automaticamente, mediante os dados fornecidos pelo(a) autor(a)

Q3c

Queiroz, Danielly

Classificação de imagens de textura geradas por Gráficos de Recorrências no problema de pessoas sofrendo ataques epiléticos. / Danielly Queiroz. - 2019.
58 f. : il.

Orientador: Valmir Macário Filho.
Inclui referências.

Trabalho de Conclusão de Curso (Graduação) - Universidade Federal Rural de Pernambuco,
Bacharelado em Ciência da Computação, Recife, 2019.

1. Descritores de textura. 2. Classificadores. 3. Imagem de recorrência. 4. Séries temporais. 5. Saúde. I. Filho, Valmir Macário, orient. II. Título

CDD 004



MINISTÉRIO DA EDUCAÇÃO E DO DESPORTO
UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO (UFRPE)
BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO

<http://www.bcc.ufrpe.br>

FICHA DE APROVAÇÃO DO TRABALHO DE CONCLUSÃO DE CURSO

Trabalho defendido por **DANIELLY DE MOURA BORBA QUEIROZ** às 17:00 do dia 10 de dezembro de 2019, no Auditório do Departamento de Computação - DC – Sala 07, como requisito para conclusão do curso de Bacharelado em Ciência da Computação da Universidade Federal Rural de Pernambuco, intitulado " **Classificação de imagens de textura geradas por recorrência no problema de pessoas sofrendo ataques epiléticos**", orientado por Valmir Macário Filho e aprovado pela seguinte banca examinadora:

Valmir Macário Filho
DC/UFRPE

Luciano Demétrio Santos Pacífico
DC/UFRPE

Toshio Meneses Chikushi
Doutorado-UFPE

*"Rendam graças ao Senhor, pois ele é bom; o seu amor dura para sempre."
1 Crônicas 16:34*

Agradecimentos

Agradeço à Deus por me permitir ter chegado até aqui, por meio dEle encontrei forças para persistir e continuar esta jornada.

Agradeço à minha família, ao meu pai Felix que durante a caminhada virou a minha estrela, me inspirou sempre a continuar e nunca desistir. Sei o quanto ele desejava essa conquista e o quanto estaria orgulhoso. A minha mãe Simone, seu cuidado, dedicação e carinho foi que me deram força para seguir, meus irmãos Lucas e Raella, meus cunhados Amanda e Régis e meus sobrinhos Miguel e Letícia por todo apoio, incentivo e amor durante todos esses anos.

Agradeço aos meus professores que me acompanharam durante a graduação e compartilharam comigo seus conhecimentos. Dentre eles, um agradecimento especial a Valmir Macário, meu orientador, pela paciência, confiança, esforço e competência na orientação e incentivo que tornaram possível a realização deste trabalho.

Agradeço a minha turma de 2013.2, meus amigos da vida e do trabalho. Sei que com vocês posso contar todas as horas para todas as situações. Muito obrigada pela amizade e companheirismo. Um agradecimento mais que especial a Bruno Marques, que durante essa trajetória foi o meu ponto de paz e força. Obrigada por sempre me ajudar e me incentivar a não desistir, só tenho que agradecer pelo carinho, paciência e por sua capacidade de me trazer paz na correria de cada semestre e da vida.

Por fim, agradeço a todos que fizeram parte desta caminhada, direta ou indiretamente. Obrigada a todos de coração, sou grata!

"O Senhor é o meu pastor, nada me faltará."

Salmos 23:1

Resumo

A epilepsia é uma condição neurológica caracterizada pela ocorrência de crises epiléticas que se repetem em intervalos variáveis. Essas crises são manifestações clínicas de uma descarga anormal de neurônios, que são células que compõem o cérebro. Algumas particularidades tornam os diagnósticos precoces da epilepsia um grande desafio, até mesmo para clínicos mais experientes. Como auxílio médico, existem exames como o eletroencefalograma (EEG) representados por séries temporais bastante utilizado no diagnóstico da epilepsia. As séries temporais estão presentes em várias áreas de estudo, como a medicina, biologia, economia, entre outras. Seus gráficos exibem padrões ocultos e mudanças estruturais nos dados, como possuem padrões de textura bem definidos que podem ser identificados adequadamente por métodos de extração de textura. Além disso, existem diversas ferramentas para extração de informações das séries temporais, uma delas é a imagem de recorrência, que usualmente é utilizada para verificar a mudança de um padrão no sinal. Este trabalho apresenta um estudo de descritores de texturas e classificadores em imagens de pessoas saudáveis e epiléticas geradas por imagens de recorrências. Os descritores de texturas usando neste estudo foram: Padrões Binários Locais (LBP), Quantização de Fase Local (LPQ) e o Banco de Filtro de Gabor. Até o melhor do nosso conhecimento, ainda não foi realizado nenhum estudo aplicando-se esses descritores em imagens de recorrência na base utilizada neste trabalho. A avaliação é realizada através da taxa média de acerto, precisão, recall e f-measure resultante dos seguintes classificadores: *Random Forest*, e *Support Vector Machine* (SVM). Os experimentos demonstraram que o classificador SVM usando o descritor LPQ mostrou resultados promissores, obtendo 92,1% de média de acerto, recall e f-measure e para precisão obteve 92,26%.

Palavras-chave: Descritores de textura, classificadores, epilepsia, imagem de recorrência, séries temporais, saúde.

Abstract

Epilepsy is a neurological condition characterized by the occurrence of epileptic seizures that recur in variations. These seizures are clinical manifestations of an abnormal discharge of neurons, which are cells that make up the brain. Some features make early diagnosis of epilepsy a major challenge, even for the most experienced clinicians. As medical aid, there are tests such as electroencephalogram (EEG) represented by time series widely used in the diagnosis of epilepsy. Time series are present in various areas of study, such as medicine, biology, economics, among others. Your graphics expose hidden patterns and alter data such as texture patterns as well as those that can be used by texture extraction methods. In addition, there are several tools for extracting time series information, one of which is the hit image, which is currently used to verify the change of an unsigned pattern. This paper presents a study of texture descriptors and classifiers in images of healthy and epileptic people generated by recurrence images. The texture descriptors using this study were: Local Binary Models (LBP), Local Phase Quantification (LPQ) and Gabor Filter Bank. To the best of our knowledge, no study has yet been performed, applying these descriptors to base recurrence images used in this work. The evaluation is performed through the average hit, precision, recall and f-measure rate resulting from the following classifiers: textit Random Forest, and textit Support Vector Machine (SVM). The experiments showed that the SVM classifier using the LPQ descriptor showed promising results, obtaining 92.1% hit, recall and f-measure mean and for accuracy obtained 92.26%.

Keywords: Texture descriptors, classifiers, epilepsy, recurrence image, time series, health.

Lista de ilustrações

Figura 1 – Gráfico de tratamentos realizados em pacientes com epilepsia no Brasil.	14
Figura 2 – Exemplo de imagens da base	15
Figura 3 – EEG representado em forma de uma série temporal.	19
Figura 4 – Processo de classificação.	20
Figura 5 – Exemplo de imagens de textura	21
Figura 6 – Um exemplo de características LBP.	23
Figura 7 – Resultado da aplicação do filtro de Gabor em imagens	25
Figura 8 – Possíveis hiperplanos de separação e hiperplano ótimo.	27
Figura 9 – Transformação: problema não linearmente separável em um problema linearmente separável.	28
Figura 10 – Método de Classificação <i>Random Forest</i>	29
Figura 11 – Etapas de classificação de imagens de texturas de epilepsia.	35
Figura 12 – Estimação do tempo de defasagem por meio da função de informação mútua.	36
Figura 13 – Processo de extração de características.	37
Figura 14 – Processo de classificação.	38
Figura 15 – Imagens da base de dados	41
Figura 16 – Representação para diferentes valores de P e R	42

Lista de tabelas

Tabela 1 – Combinação de valores dos parâmetros R e P para o LBP	42
Tabela 2 – Combinação de valores dos parâmetros R e F para o LPQ	43
Tabela 3 – Combinação da etapa 2 dos valores dos parâmetros S e F para o GFB	44
Tabela 4 – Combinação da etapa 3 dos valores dos parâmetros S e F para o GFB	44
Tabela 5 – Melhores resultados	45
Tabela 6 – Experimentos utilizando o Descritor LBP	46
Tabela 7 – Experimentos utilizando o Descritor LPQ	47
Tabela 8 – Experimentos utilizando o Banco de Filtros de Gabor	48
Tabela 9 – Experimentos das combinações dos melhores resultados	48
Tabela 10 – Tempo médio para coleta dos Descritores	49
Tabela 11 – Matriz de confusão	49

Lista de abreviaturas e siglas

EEG	Eletroencefalograma
LBP	Padrões Binários Locais
LPQ	Quantização de Fase Local
GFB	Banco de Filtro de Gabor
RF	Random Forest
SVM	Máquina de Vetores de Suporte
UFRPE	Universidade Federal Rural de Pernambuco

Sumário

	Lista de ilustrações	8
1	INTRODUÇÃO	13
1.1	Problema de Pesquisa	15
1.2	Objetivos	16
1.3	Estrutura do trabalho	16
2	CONCEITOS	18
2.1	Epilepsia	18
2.2	Séries Temporais	19
2.2.1	Imagens de Recorrência	20
2.3	Textura	21
2.4	Descritores de textura	22
2.4.1	Padrões Binários Locais (<i>LBP</i>)	22
2.4.2	Quantização de Fase Local (<i>LPQ</i>)	24
2.4.3	Banco de Filtros de Gabor	24
2.5	Classificações de imagens	26
2.5.1	Máquina de Vetores de Suporte (<i>SVM</i>)	26
2.5.2	Floresta Aleatória	28
3	ESTADO DA ARTE	30
4	CLASSIFICAÇÃO DE IMAGENS DE TEXTURAS DE EPILEPSIA	35
4.1	Transformação de serie temporal em imagem de recorrência	35
4.2	Avaliação de diferentes algoritmos de descritores	37
4.3	Avaliação de diferentes algoritmos de classificação	38
5	ANÁLISE EXPERIMENTAL	40
5.1	Ambiente Experimental	40
5.2	Construção da Base de Dados	40
5.3	Análise dos Parâmetros	41
5.3.1	Padrão Binário Local (<i>LBP</i>)	42
5.3.2	Quantização de Fase Local (<i>LPQ</i>)	42
5.3.3	Bancos de Filtros de Gabor (<i>GFB</i>)	43
5.4	Avaliação dos Experimentos	44
6	RESULTADOS	46

6.1	Discussão	50
7	CONCLUSÃO E TRABALHOS FUTUROS	52
7.1	Trabalhos Futuros	53
7.2	Contribuições	53
	REFERÊNCIAS	54

1 Introdução

A epilepsia é uma condição neurológica que afeta o sistema nervoso. Isto é, uma doença resultante de uma anomalia cerebral ([Hospital Israelita Albert Einstein, 2016](#)). A epilepsia também é conhecida como um distúrbio convulsivo, o seu diagnóstico geralmente é realizado quando o paciente teve pelo menos duas crises que não foram causadas por alguma condição médica conhecida ([FOUNDATION, 2014](#)). Existem outros distúrbios que podem causar alterações no comportamento causando convulsões, e estas são confundidas com epilepsia. É de extrema importância que o diagnóstico seja preciso, certificando se o paciente tem epilepsia para que assim o tratamento da doença seja realizado de forma eficaz ([TEIXEIRA, 2017](#)).

Além disso, a epilepsia é uma doença que atinge uma parte significativa da população mundial, mais de 50 milhões de pessoas ao redor do mundo têm epilepsia, sendo capaz de atingir pacientes de qualquer raça, gênero e faixa etária de idade. Espera-se que o número de pessoas com epilepsia aumente ainda mais ([ORGANIZATION, 2019](#)).

Além disso, segundo o portal ([FOUNDATION, 2014](#)), referência em pesquisas sobre epilepsia, o número de pessoas na Terra que vivem com convulsões ativas a qualquer momento é entre 4 e 10 de 1000, e 6 de 10 é o número de pessoas com epilepsia em que a causa é desconhecida e nenhum tratamento disponível funciona para elas.

É de extrema importância que o diagnóstico da doença seja realizado precocemente, sendo possível descobrir as causas e o tratamento necessário. Não é possível impedir que a doença seja desenvolvida em um paciente, mas pode ser prevenida através de um sono regularizado, consumo moderado de bebidas alcoólicas e evitar ambiente com fortes estímulos luminosos ([Assistência à Saúde de Pacientes com Epilepsia \(ASPE\), 2018](#)).

Existem tratamentos que podem ser bastante eficazes no controle da doença. Na maioria dos casos o tratamento é realizado através de medicamentos que reduzem as chances de ataques epiléticos. Esse tratamento é eficaz em cerca de 70% dos pacientes que são tratados apenas com o uso regular de medicações. Mas em alguns casos são indicados procedimentos médicos, como o tratamento cirúrgico, possibilitando o controle das crises ([Revista Saúde Abril, 2017](#)). A seguir a Figura 1 mostra os tratamentos realizados em 2 Milhões de pessoas que sofrem dessa doença no Brasil e seus resultados.

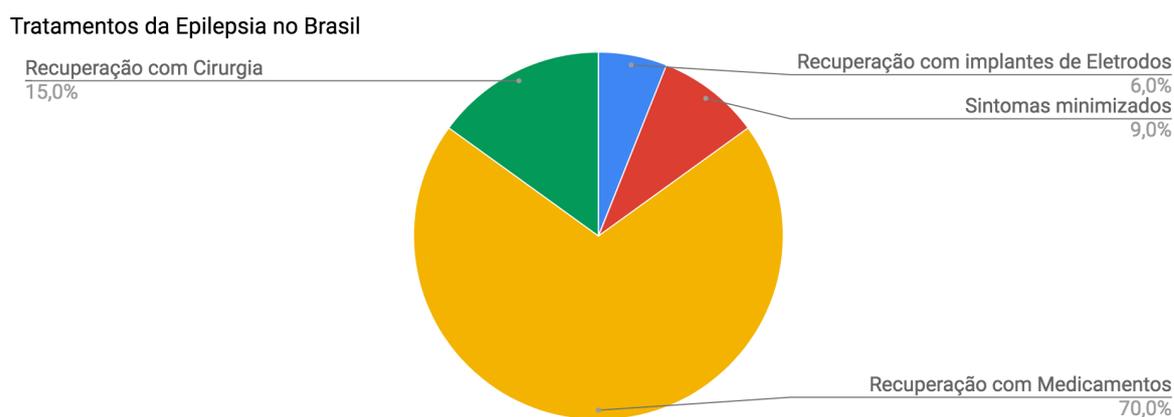


Figura 1 – Gráfico de tratamentos realizados em pacientes com epilepsia no Brasil.

Fonte – Fonte: Veja, São Paulo - Acessado em 24-10-2018

Como se pode observar na Figura 1, 70% dos pacientes conseguiram se recuperar com o uso de medicamentos; 15% necessitaram de tratamentos cirúrgicos para se recuperarem; 6% necessitam de implantação de eletrodos no cérebro para normalizar os impulsos elétricos entre os neurônios e 9% já tentaram todos os tratamentos anteriores, mas, apesar dos sintomas terem sido reduzidos, não se recuperaram totalmente.

Apesar da grande parte dos pacientes conseguirem se recuperar através dos tratamentos, há alguns obstáculos e desafios para diagnosticar a doença. Hoje em dia, o exame de monitoramento eletroencefalograma (EEG) é bastante utilizado para auxiliar diagnósticos de doenças, especialmente para a epilepsia. O EEG tem o objetivo de registrar a atividade elétrica do cérebro, onde é possível detectar e fornecer informações decisivas para diagnosticar a doença (GALVAO et al., 2005). Porém, existe uma grande complexidade de interpretação e dependência de um observador, podendo gerar falsos positivos.

Sendo assim, afim de minimizar estes desafios e obstáculos, a proposta deste trabalho é automatizar e fornecer mais um método para auxiliar o diagnóstico dessa doença, através da detecção de padrões de textura em imagens geradas a partir dos sinais coletados em exames EEG de pacientes com epilepsia. A abordagem visa selecionar descritores de textura para obtenção de características da imagem e avaliá-los através de algoritmos de inteligência artificial para classificar automaticamente essas imagens como sendo de pessoas saudáveis ou com ataque epiléptico.

1.1 Problema de Pesquisa

Algumas particularidades tornam os diagnósticos precoces da epilepsia um grande desafio, até mesmo para clínicos mais experientes. Exames de monitoramento não-invasivos, como o EEG, são utilizados para diagnosticar doenças como a epilepsia (Minutos Saudável, 2017). Esses exames possuem grande complexidade de interpretação e dependência de um observador, podendo gerar diagnósticos com falso positivo e negativo. Segundo o artigo de Teixeira (TEIXEIRA, 2017), no Brasil grande parte dos especialistas em neurofisiologia que interpretam esse tipo de exame não foram adequadamente treinados, e não possuem certificado de especialização.

Nesse cenário, o problema de pesquisa é detectar padrões de texturas em imagens obtidas a partir de atributos estatísticos dos sinais do exame EEG, que possam indicar epilepsia em imagens de séries temporais utilizando algoritmos de inteligência artificial. A extração automatizada de informações em imagens médicas não é uma tarefa simples e apresenta vários desafios (PHAM, 2018) como: i) uma abordagem estatística descritiva do sinal ii) gerar imagens de textura a partir de imagem de recorrência; iii) selecionar e avaliar descritores de textura eficientes; e iv) realizar a classificação corretamente.

Então, como forma de aumentar a precisão dos diagnósticos a abordagem apresentada, afasta-se dos métodos convencionais para o problema de crises epiléticas, visando automatizar os diagnósticos através de extração de características de imagens de textura obtidas a partir de extração de características dos sinais de eletroencefalograma de pacientes epiléticos. A Figura 2 é um exemplo de imagens da base que serão utilizadas para a automatização.

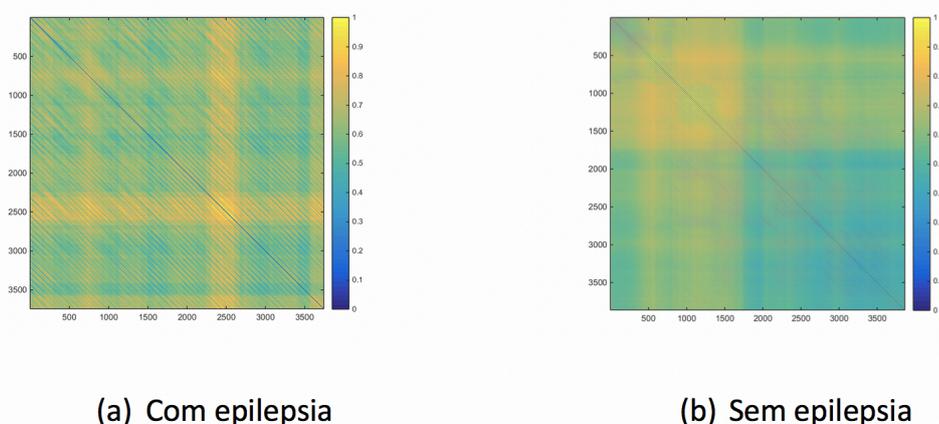


Figura 2 – Exemplo de imagens da base

Fonte – Do Autor

A Figura 2 representa registros de eletroencefalogramas transformados em imagens de textura.

As imagens apresentadas na Figura 2 foram geradas através da transformação dos exames EEG em gráficos de recorrências, com o objetivo de facilitar a extração de informações e descoberta de padrões, a partir da análise da recorrência dos estados relacionados ao processo gerador de sinal. Dessa forma, este trabalho analisou o padrão de textura dos gráficos de recorrências para diferenciar pacientes saudáveis e com epilepsia. No conhecimento dos autores, ainda não houve um trabalho que utilize padrões de textura para classificação desse padrão de sinal. Para isto, foi utilizado descritores de texturas como o Padrões Binários Locais (LBP), Quantização de Fase Local (LPQ) e o Banco de Filtro de Gabor. E a avaliação dos métodos foi realizada através da taxa média de acerto resultante da aplicação dos seguintes classificadores: *Random Forest*, e *Support Vector Machine (SVM)*.

1.2 Objetivos

Objetivo Geral:

Classificar imagens de textura geradas por gráficos de recorrências no problema pessoas sofrendo ataques epiléticos.

Objetivos Específicos:

- Selecionar descritores de características de imagens de textura no problema de pessoas em ataque epilético.
- Avaliar algoritmos na tarefa de classificar imagens de ataques de epilepsia.
- Realizar busca por parâmetros que melhorem os resultados do classificador.

1.3 Estrutura do trabalho

O Capítulo 2 deste trabalho apresentará uma introdução sobre a Epilepsia, séries temporais e as técnicas utilizadas, no contexto envolvendo processamento de imagens, descritores e classificadores. O Capítulo 3 apresenta os conceitos e soluções para problemas encontrados no estado da arte. O capítulo 4 apresenta as etapas do processo para classificar as imagens através das técnicas de textura. O Capítulo 5 apresenta todo o material e análise aplicada nos experimentos. O Capítulo 6 descreve

os resultados obtidos para cada experimento realizado. E o Capítulo 7, a conclusão e os trabalhos futuros.

2 Conceitos

2.1 Epilepsia

A epilepsia é uma doença causada por uma descarga elétrica súbita, anormal e desordenada dos neurônios. Essas descargas podem compreender uma, várias ou todas as categorias e níveis do sistema nervoso. Porém crises epiléticas isoladas ou ocasionais, causadas por doenças agudas, não devem ser classificadas como epilepsia (MOREIRA, 2004).

Também, observa-se que existem vários tipos de tipos e acessos epiléticos, bem como doenças que se assemelham à epilepsia. Estas podem, como os acessos epiléticos, ser caracterizadas por sintomas ocasionais e até mesmo por convulsões. Então é importante destacar que nem toda convulsão é sinônimo de epilepsia, portanto outras possibilidades diagnósticas têm que ser consideradas.

É notável que procedimentos para se chegar ao diagnóstico avançam cada vez mais, identificando os múltiplos fatores que causam epilepsias. Na maioria das vezes que há suspeita de epilepsia, um dos primeiros exames ainda solicitados pelos médicos é o EEG (MOREIRA, 2004). Esse tipo de exame é uma ferramenta que oferece dados através de séries temporais que registra a atividade elétrica do cérebro em forma de sinais. A atividade elétrica reflete o estado funcional em dado momento. Ele é utilizado no diagnóstico de epilepsia e nos episódios de não epilepsia, seu funcionamento ocorre pela colocação dos eletrodos no couro cabeludo do paciente, onde são capturados sinais elétricos que constituem a atividade cerebral. Apesar de ser uma ferramenta bastante utilizada, existe uma grande complexidade quanto a ela, os exames devem ser realizados por profissionais especialistas em EEG. Essa complexidade ocorre por diversos fatores, como:

- A colocação dos eletrodos é primordial. São 23 deles, cada um com espaçamento específico do outro, e todos precisam ser colocados para a transmissão perfeita da atividade elétrica;
- O monitoramento das condições do paciente durante o procedimento bem como o correto registro de suas atividades anteriores, são imprescindíveis para uma boa captura das atividades elétricas e, por consequência, de um laudo com qualidade;
- Interpretação complexa dos sinais.

Para uma doença como epilepsia é fundamental que diagnósticos sejam realizados de maneira correta, pois o diagnóstico é um princípio importante para que se possa melhorar e até caminhar para a cura total da doença. Mas é a partir da precisão dele que se pode conduzir qual a melhor adequação na terapêutica medicamentosa a ser ministrada no tratamento.

2.2 Séries Temporais

Uma série temporal é composta por uma sequência de observações ordenadas pelo tempo e que apresenta intervalos de tempo iguais entre cada par de observações (AMARAL; SOUSA, 2016). Por causa do aumento das bases de dados em diversos domínios como medicina, economia, epidemiologia, meteorologia e etc, surgiu o grande interesse de analisar esses dados. Na área de medicina, por exemplo, há uma grande disponibilidade de base de dados no formato de séries temporais, como o EEG e ECG (eletrocardiograma), mesmo que a série temporal apresente uma grande complexidade, o que causa um custo significativo para o processo de supervisão manual pelo médico ou especialista (THIELO; REZEND, 2000). A Figura 3 representa um exame EEG que registra a diferença entre os eletrodos periodicamente sob a forma de uma série temporal.

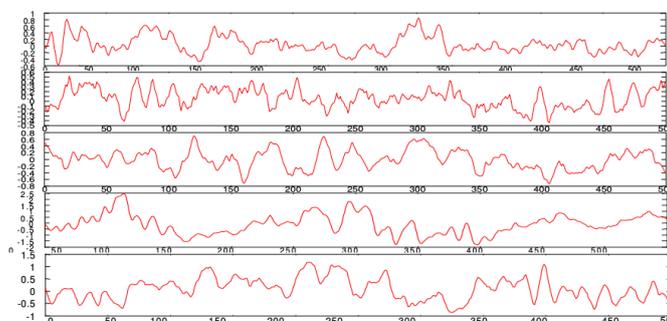


Figura 3 – EEG representado em forma de uma série temporal.

Fonte – (THIELO; REZEND, 2000)

A suposição básica da análise de séries temporais é que existe um sistema causal mais ou menos constante, relacionado com o tempo, que exerceu influência sobre os dados no passado e pode continuar a influenciá-lo no futuro (AMARAL; SOUSA, 2016). Então a análise de séries temporais se torna importante, porque torna possível identificar padrões não aleatórios na série temporal de uma variável de interesse. E com os padrões identificados podem se realizar previsões sobre o futuro, orientando a tomada de decisões.

2.2.1 Imagens de Recorrência

A recorrência é uma característica do que é recorrente, do que retorna, e se repete. Ela é uma propriedade fundamental de sistemas dinâmicos, que são sistemas físicos que evoluem no tempo. Geralmente são sistemas com comportamentos complexos não lineares e estudados por meio de séries temporais (MARWAN et al., 2007). O gráfico de recorrência, também denominado por *Recurrence Plot* (RP), uma técnica usada para extração de séries temporais que tem como objetivo facilitar a extração de informações e descoberta de padrões a partir da análise da recorrência de uma sequência de estados de sistema subjacente (EDERLON; BARBOSA; CRUZ, 2016).

Nesta análise, uma recorrência é definida sempre que um estado x_i em um tempo $t = i$ é similar ao estado do sistema x_j em outro tempo $t = j$. Ou seja, o estado x está muito próximo ao estado de tempo $t = i$. Um estado x_i qualquer é dito recorrente se, durante a trajetória do sistema, um novo estado x_j ($i \neq j$) estiver muito próximo de x_i no espaço de fase.

A construção do RP de uma série temporal de N pontos é representada por uma matriz binária de tamanho $N \times N$. A partir desta matriz de recorrência R , uma recorrência é definida como $R_{ij} = 1$, se o estado x_i for vizinho de x_j no espaço de fase, caso contrário, $R_{ij} = 0$. Um estado x_i qualquer é dito recorrente se, durante a trajetória do sistema, o estado x_j estiver próximo o bastante de x_i no espaço de fase respeitando um limiar ε (ELISANGELA; SANTOS, 2019). A Figura 4 mostra um exemplo do resultado final de uma transformação de série temporal em tempo real a partir do conjunto de dados e um exemplo de Gráfico de Recorrência considerando essas séries em tempo real para o caso de escala de cinza. Note que a Gráfico de Recorrência possui um determinado padrão. Esse padrão, podemos denominar de padrão de textura, conceito que será explicado na seção 2.3.

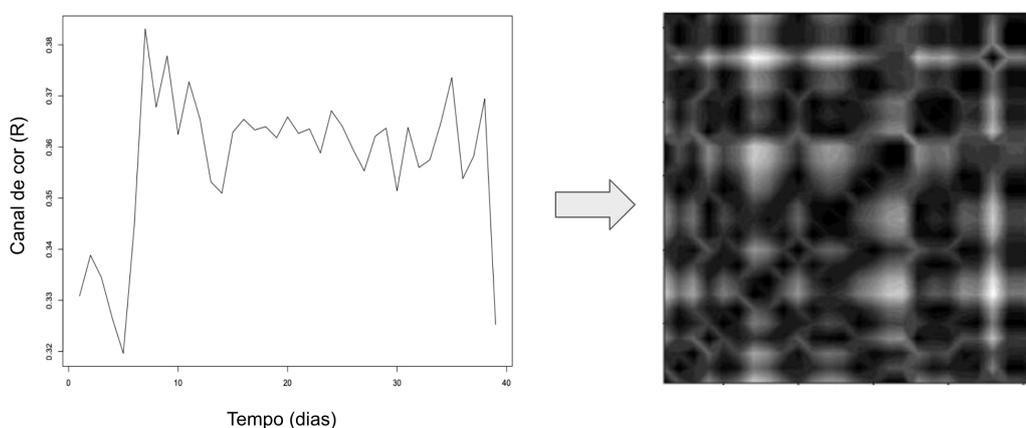


Figura 4 – Processo de classificação.

Fonte – (ELISANGELA; SANTOS, 2019)

2.3 Textura

As texturas podem ser facilmente percebidas pelo ser humano, elas são padrões visuais compostos por sub-padrões que podem ser definidos, por exemplo, como brilhos, cor, forma ou tamanho. Não existem ainda definições satisfatórias na literatura de textura, mas podemos dizer que textura é uma propriedade que é possível sentir através de características percebidas pelo toque humano como rugosidade, profundidade, regularidade, suavidade, uniformidade ou até mesmo conseguir visualizar características como os padrões repetidos ou aleatórios e variações de brilhos (SIMON; UMA, 2018). A Figura 5 mostra alguns exemplos de texturas.

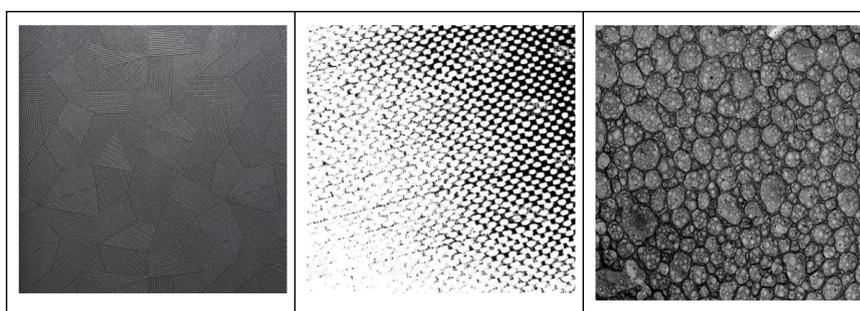


Figura 5 – Exemplo de imagens de textura

Fonte – (ULYANOV et al., 2016)

Com isso, ela é uma das características mais importantes para o reconhecimento e classificação de objetos e cenas. Ela pode ser representada por variações locais em valores de pixels que se repetem de maneira aleatória ou regular ao longo do objeto ou imagem (ALVES; WONDER; LIBRANTZ, 2013). O processo de reconhecimento e classificação de textura tem sido um tópico de pesquisa relevante na literatura por causa da sua importância, tanto na compreensão de como o processo de reconhecimento de textura funciona em seres humanos, bem como no importante papel que desempenha na grande variedade de aplicações de visão computacional e análise de imagens (Liu et al., 2016).

Através da textura é possível obter informações que podem ser utilizadas para diversas aplicações, como análise e compreensão de imagens, reconhecimento de objetos e biometria, recuperação de imagens com base em conteúdo, classificação de documentos e até mesmo extração de características de imagens para automatizar o processo de diagnóstico de doenças como tumores (FISSEHA et al., 2015), câncer de mama (MOHAMED et al., 2017), Parkinson, Huntington, esclerose lateral amiotrófica (PHAM, 2018), epilepsia (RAJEANDRA et al., 2013), etc.

2.4 Descritores de textura

Os descritores são algoritmos que a partir da sua aplicação é possível obter valores que representam características como forma, curvas, cor, textura e medidas estatísticas da imagem. Ou seja, dessa forma é possível obter informações relevantes extraídas dos padrões existente, que podem auxiliar para a resolução de determinado tipo de problema ou representação desse problema (HASSABALLAH; AWAD, 2016).

Os descritores de textura são utilizados para obter informações a partir da extração das características da textura de imagens. Segundo (SIMON; UMA, 2018) a classificação de textura tem como objetivo encontrar um descritor de textura que seja eficiente e discriminativo. Esses descritores texturais obtém os recursos e os representam com eficiência, possibilitando maior precisão na classificação. A maioria dos descritores de textura são simples e baseados em orientações, arranjos espaciais de pixels, uniformidade, histograma e gradientes. Na literatura encontra-se descritores com ótimos resultados para análise e classificação de textura como os Padrões Binários Locais (LBP), Quantização de Fase Local (LPQ) e Banco de Filtro de Gabor, que serão explicados a seguir.

2.4.1 Padrões Binários Locais (LBP)

Um método de análise de micro padrões proposto por Ojala *et al.* (OJALA; PIETIKÄINEN; HARWOOD, 1996), o LBP tem como objetivo realizar comparações do pixel central com os seus 8 pixels vizinhos adquirindo um código que caracterize a micro região selecionada.

Considere que uma janela de pixel 3x3 é retirada da imagem que correspondem aos pixels $\vec{v} = (V_0, V_1, \dots, V_8)$, onde V_0 representa o valor da escala de cinza central, ou seja, ele é o pixel central e V_i representa o valor de escala de cinza do seus 8 vizinhos. A partir disso, é aplicado uma comparação considerando três possíveis cenários: i) O pixel central possui o mesmo valor que o seu pixel vizinho; ii) o pixel central é menor que o seu pixel vizinho; iii) ou o pixel central é maior que o seu pixel vizinho.

A definição do LBP é composta por um conjunto que contém 8 elementos $LPB = (E_1, E_2, \dots, E_8)$, obtido através da comparação de V_i pixels vizinhos com seu pixel central o V_0 , tal que:

$$E_i = \begin{cases} 1, & \text{se } V_i \geq V_0 \\ 0, & \text{se } V_i < V_0 \end{cases}$$

Então durante a comparação, se o valor do pixel vizinho for menor que o valor do pixel central, o resultado de será 0. E se o valor do pixel for maior ou igual ao valor do pixel central, o resultado será igual a 1. A partir disso é obtida a nova matriz de vizinhança que será multiplicada por uma matriz de peso, que de acordo com a fórmula relatada a seguir será obtido o código do LPB, capaz de caracterizar um determinado micro padrão da imagem.

$$Code_{LBP} = \sum_{i=1}^8 E_i * 2^i - 1 \tag{2.1}$$

Logo após a obtenção do código LBP é formado um histograma que é considerado um vetor de características. A figura 6 exemplifica o processo de como obter o código LBP.

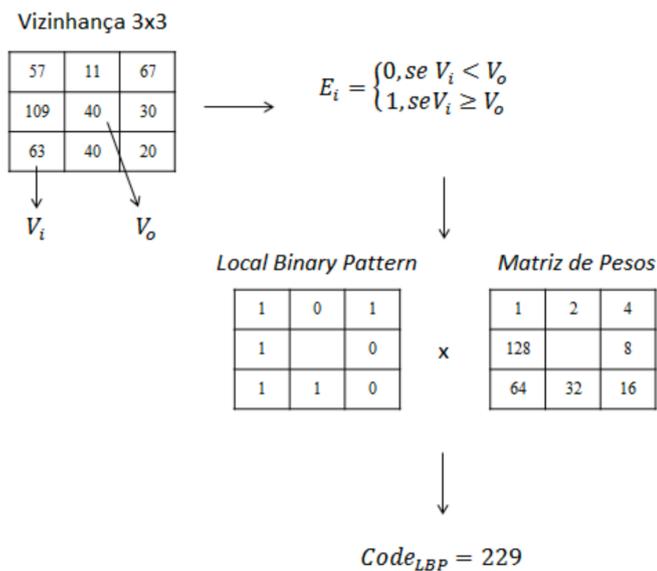


Figura 6 – Um exemplo de características LBP.

Fonte – (TRAVAINI, 2015)

Com o objetivo de tornar o LBP constante a rotações na imagem e capaz de realizar análises multi-escalares, foi proposto o LBP circular. Para obter a vizinhança circular, a quantidade de vizinhos (quantidade de pontos P) é escolhida a partir do tamanho do perímetro circular (Raio R). Para obter o valor em escala de cinza dos pixels, é realizada uma interpolação da vizinhança com espaçamento igual no círculo (TRAVAINI, 2015).

Além disso, uma técnica bastante utilizada no LBPs é a de padrões uniformes (LBP-U). Ela pode ser aplicada para obter invariância contra rotações e padrões repetitivos, como os de texturas em imagens. Um LBP é uniforme quando contém no máximo duas transições de '1 a 0' ou '0 a 1', por exemplo: 000100 possui duas transições (é LBP-U), 0101010010 possui oito transições (não é LBP-U). Ao calcular o histograma LBP, um valor separado é designado para cada padrão uniforme e todos os padrões não uniformes recebem um valor exclusivo. Usando esta técnica, você pode reduzir o comprimento de um vetor de 256 para 59 espaços, por exemplo, otimizando assim o LBP (MING; WANG; FAN, 2015).

2.4.2 Quantização de Fase Local (LPQ)

O método Quantização de Fase Local (LPQ) tem como fundamento a invariância de desfoque do espectro da fase de Fourier. Ele é um descritor gerado com a finalidade de superar o LBP em aplicações em imagens borradas ou afetadas pela iluminação não uniforme. O LPQ utiliza as informações da fase local extraídas usando a Transformada de Fourier (STFT), que é calculada sobre uma vizinhança retangular $M \times M$ em cada posição de pixel x da imagem. Além disso a quantização de fase leva em conta apenas o sinal das componentes real e imaginária da transformada de Fourier $F_w(u)$, $u = (u, v)$, em pelo menos quatro valores de frequências próximos à origem, especificamente $(0, a)$, (a, a) , $(a, 0)$ e $(a, -a)$. A partir disso, são gerados 8 bits, que assumem o valor 0 ou 1, dependendo de cada valor ser negativo ou não-negativo. Estes bits são concatenados em uma ordem arbitrária, porém fixa, formando um valor inteiro de 8 bits que representa a textura (MARCELO et al., 2011).

É importante destacar que as informação contida em $F_w(u)$ se concentra nas frequências mais baixas. Além disso, o valor da Transformada de Fourier na origem corresponde ao brilho médio da vizinhança, o que, para efeitos de textura, é irrelevante. Assim, as componentes e suas simétricas são os 8 componentes de $F_w(u)$ onde se concentra a maior parte da informação da textura. A partir disso, é gerado um histograma desses valores inteiros de todas as posições da imagem, que será utilizado como um vetor de característica de 256 dimensões na classificação.

2.4.3 Banco de Filtros de Gabor

O Banco de Filtros de Gabor (GFB) é um dos métodos mais eficientes para análise de textura. Ele analisa as informações das bordas do conteúdo da imagem, extraindo informação sobre a orientação da imagem e sua textura, utilizando diferente escalas e ainda é invariante à iluminação (DORA et al., 2019). O Filtro é uma onda senoidal no domínio espacial que é modulada por um envelope gaussiano. A largura da banda do filtro é determinada através do desvio padrão da Gaussiana, enquanto a

direção e a frequência do sinal sinusoidal são a direção e frequência do filtro passa-banda. Após a convolução do GFB na imagem, é obtido um vetor de características que consiste em médias e desvio padrões. Nos últimos anos, a utilização do Banco de Filtros de Gabor cresceu consideravelmente devido a sua ótima localização de padrões em ambos domínios espaciais e de frequência, sendo assim tornou-se uma das abordagens mais populares (Li et al., 2010).

Como foi relatado anteriormente, o GFB é uma onda senoidal complexa, modulada pelo envelope gaussiano e a sua forma de domínio espacial é dada pela equação a seguir:

$$\delta(x, y, f, \theta) = \frac{f^2}{\pi\gamma\eta} e^{-\left(\frac{f^2}{\gamma^2}x'^2 + \frac{f^2}{\eta^2}y'^2\right)} e^{i2\pi f x'} \quad (2.2)$$

Onde f representa a frequência do sinal senoidal da onda θ corresponde a rotação do envelope gaussiano γ e η são os parâmetros de suavização do envelope Gaussiano. A Figura 7 representa exemplos da aplicação do GFB.

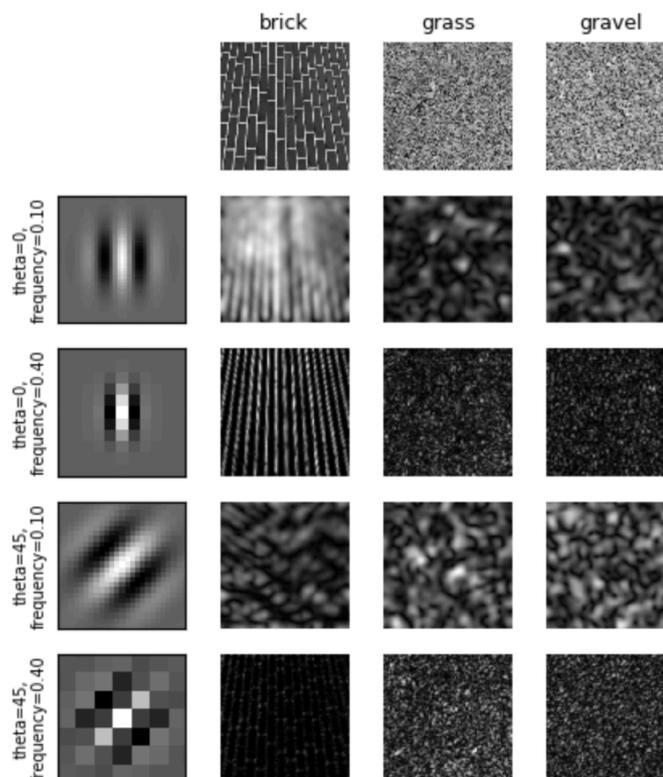


Figura 7 – Resultado da aplicação do filtro de Gabor em imagens

Fonte – (Li et al., 2010)

Portanto, com a variação dos parâmetros relatados é possível melhorar as propriedades visuais de uma imagem, como por exemplo a frequência espacial e a orientação. O vetor característica de Gabor é obtido através da aplicação de um filtro sobre a imagem e transformando a resposta em um vetor unidimensional, que será utilizado como entrada para classificação e soluções de problemas.

2.5 Classificações de imagens

A classificação de imagens tem como objetivo determinar um mapeamento que relacione as propriedades extraídas de amostras com um conjunto de rótulos (classes). Os algoritmos que visam estabelecer o mapeamento entre as propriedades das amostras e o conjunto de rótulos são denotados algoritmos de classificação ou classificadores (CERQUEIRA; ALVES, 2010). Neste trabalho foram utilizados dois classificadores: Máquinas de Vetores de Suporte e Floresta Randômica que serão explicados, respectivamente, nas seções 2.5.1 e 2.5.2.

2.5.1 Máquina de Vetores de Suporte (SVM)

A Máquina de vetores de suporte (*support vector machines* – SVM) tem a capacidade de solucionar problemas de classificação, obtendo com o aprendizado na etapa de treinamento a capacidade de generalização. Considere que exista um problema binário, o objetivo da SVM é fazer a separação das instâncias das duas classes por intermédio de um limite que será adquirida a partir da fase de treinamento (SHUJUN et al., 2018). A partir disso é produzido um classificador que funcionará para os exemplos não aplicados na fase de treinamento, isto é, ter a capacidade de prever as saídas de futuras novas entradas. O limite de decisão é conhecido como hiperplano, a SVM busca o hiperplano máximo, isto é, a maior separação ou margem entre as duas classes. A imagem 8 demonstra um conjunto de classificadores lineares que separam duas classes, mas apenas um que está em destaque na imagem é o que maximiza a separação das duas classes e ele é o denominado de Hiperplano ótimo.

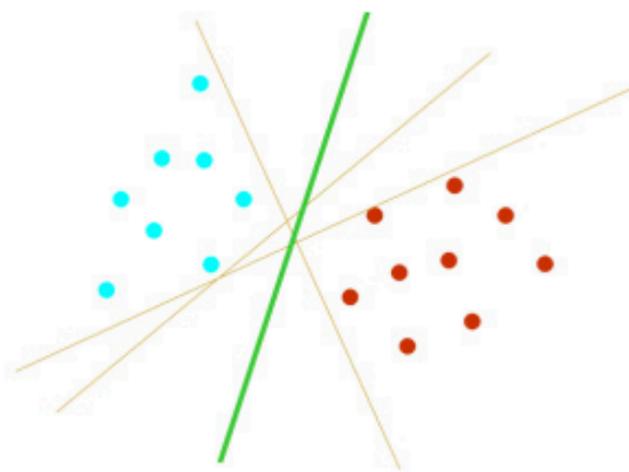


Figura 8 – Possíveis hiperplanos de separação e hiperplano ótimo.

Fonte – (GILSON MEDEIROS, 2017)

Além disso, em casos que precisam classificar dados que não são linearmente separáveis, a função do hiperplano é modificada. Ela utiliza sua técnica chamada "truque de núcleos". Esta técnica possui funções chamadas de núcleos (*kernels*) que projetam os vetores de características de entrada em um espaço de características de alta dimensão para classificação de problemas que se encontram em espaços não linearmente separáveis. Esse processo é realizado, pois a medida que se aumenta o espaço da dimensão do problema, aumenta também a probabilidade desse problema se tornar linearmente separável em relação a um espaço de baixa dimensão. Seu papel é realizar transformações de dados extremamente complexos e, em seguida, descobrir o processo para separar os dados com base nos rótulos ou saídas que foram definidas. A Figura 9 mostra o processo de transformação de um problema não linearmente separável, em um problema linearmente separável através do aumento da dimensão, onde é feito um mapeamento por uma função de *kernel* $F(x)$.

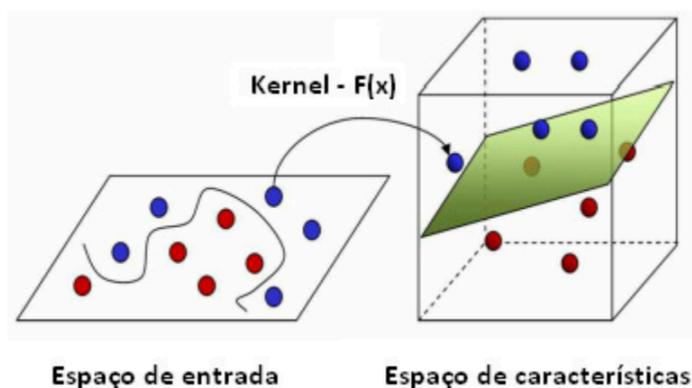


Figura 9 – Transformação: problema não linearmente separável em um problema linearmente separável.

Fonte – (GILSON MEDEIROS, 2017)

2.5.2 Floresta Aleatória

O algoritmo de classificação de Floresta Aleatória (*Random Forest*) utiliza o método de árvores de decisão que possibilita a exploração de uma grande quantidade de dados de entrada. O *Random Forest* diferencia dos algoritmos de árvores de decisão pelo motivo de que uma árvore de decisão é construída a partir de uma base de dados, já o *Random Forest* tem como objetivo gerar várias árvores de decisão através de um subconjunto de atributos que são escolhidos aleatoriamente.

Após a construção desses subconjuntos de árvores é possível executar a classificação da qual obteve o melhor ganho de conhecimento para a solução de um determinado problema, para que isso ocorra é necessário selecionar um subconjunto que tenha melhor lógica e vantagens para a tomada de decisão. Isto é, para cada subconjunto é atribuído um voto sobre qual classe o atributo chave deve pertencer, este voto possui um “peso” onde o mesmo é afetado pela igualdade entre as árvores, ou seja, quanto menor for a similaridade entre duas árvores e sua precisão for maior, melhor será a sua nota. Segundo (CASSIO et al., 2016), o *Random Forest* possui características que se destacam entre outras técnicas, algumas delas são:

- Algoritmo mais poderoso do que comparado somente a uma árvore de decisão;
- Possui boa taxa de acerto quando testado em diferentes conjuntos de dados;
- Técnica exata;
- Menos sensíveis a ruídos;
- Classificação aleatória das árvores sem intervenção humana.

A seguir é demonstrado pela Figura 10 o processo do método de classificação do *Random Forest*:

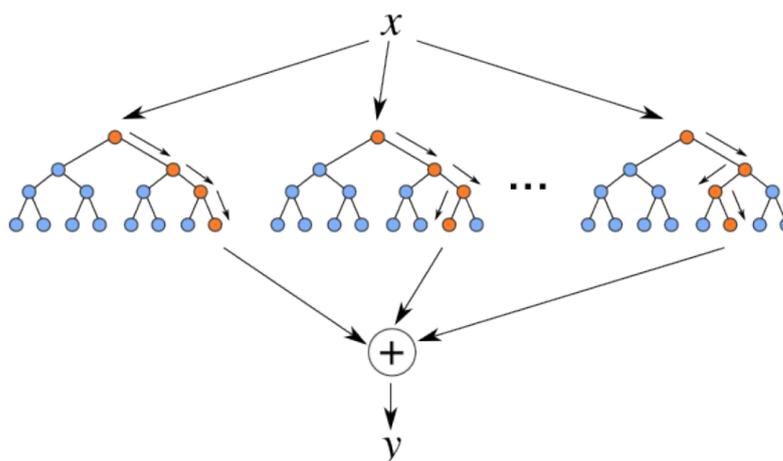


Figura 10 – Método de Classificação *Random Forest*

Fonte – (CASSIO et al., 2016)

Na Figura 10 é possível perceber que partindo de uma base de dados (representado pelo elemento X gerou-se várias árvores, onde serão geradas várias regras para cada uma e nelas, a possibilidade de descoberta de novos padrões podem ser decisivas na tomada de decisão adequada. A partir da criação dessas árvores é possível calcular qual delas contém a regra mais exata para solucionar um determinado problema. Na imagem anterior é possível verificar que partindo de um elemento X , no caso uma base de dados, gerou-se várias árvores de decisão, neste ponto cada uma gera várias regras e nelas a possibilidade de descoberta de novos padrões que poderão ser decisivos na tomada de decisão correta. Com as florestas criadas o próximo passo é calcular qual delas contém as regras mais exatas para a mineração. Com a escolha realizada é aplicado na base de dados as mesmas e assim chegando a um resultado Y .

3 Estado da Arte

É de extrema importância que o diagnóstico de doenças como a epilepsia seja realizado precocemente e de forma correta, sendo possível descobrir as causas e o tratamento necessário. Sinais cerebrais são registrados por exames EEG, que podem ser transformados em imagens de séries temporais que possuem padrões de texturas. Esses padrões são utilizados como recursos preditivos para classificações desse tipo de imagens (PHAM, 2018). Na literatura é possível encontrar diversos métodos e estudos que buscam resolver de alguma forma, o problema de classificação imagens de textura. Isso resulta em experimentos de algoritmos de extração de textura de imagens para diferentes doenças ou outros objetivos.

(SOUZA; SILVA; BATISTA, 2014) propõem um método que investiga o uso de gráficos de recorrência como representação de dados para classificar séries temporais, através da recorrência e extração de características de textura das imagens. É realizada uma comparação de métodos que apresentaram ótimos resultados em trabalhos na literatura: o 1-NN com distância euclidiana (ED), Dynamic Time Warping (DTW) e Recorrência de Padrões de Distância de Compressão (RPCD). Dessa forma, o seu método consiste em combinar as características extraídas dos dados através de descritores de texturas como LBP, Matriz de Coocorrência de Nível Cinza (GLCM), Filtros Gabor e Análise de Textura Fractal Baseada em Segmentação (SFTA). Sendo assim, a combinação resultou em uma grande quantidade e até mesmo redundância de características e com intuito de melhorar o resultado, é realizada uma seleção para abranger diversas visões da análise de textura. Dessa forma, com as características reduzidas e utilizadas como atributos, a classificação dos dados é executada através do algoritmo de aprendizagem de máquina, o SVM. Portanto, na análise dos resultados do método apresentado, segundo os autores, o método proposto obteve maior relevância do que os principais métodos encontrados na literatura.

(MASOOD et al., 2016) realizam uma análise de descritores de textura para classificação de imagens a partir do uso de métodos de extração de textura. O objetivo do trabalho foi analisar descritores de textura de última geração para classificação e fornecer uma comparação entre estes descritores. Dessa forma, os descritores escolhidos para realizar os experimentos são o LBP e suas extensões, Wavalets Gabor e análise fractal. Após a utilização dos descritores para a extração de características foi realizada uma comparação do desempenho da classificação em relação as bases de dados. Para isso foi usando o classificador K-vizinho mais próximo (KNN). Por fim, com os resultados obtidos da precisão de desempenho de todos os descritores aplicados nos conjuntos de dados, os autores compararam os resultados e chegaram a

conclusão que nenhum descritor é superior em relação a todos os conjuntos de dados, já que houve uma variação para cada descritor em diferentes bancos de dados.

([PHILOMINA; SIMON, 2018](#)) apresentam uma revisão de descritores para Classificação de Textura que é um processo de diferenciar ou classificar vários tipos de texturas em classes separadas. Um estudo dos descritores encontrados na literatura é realizado e resumido em um quadro geral com a classificação de texturas e a significância de cada um. Para isso, foi analisado mais de cinquenta descritores de textura recentemente desenvolvidos através da aplicações de diferentes técnicas de classificação em vários bancos de dados. Dessa forma, foi possível descobrir que os métodos de classificação de textura podem ser agrupados baseados em filtro, baseado em histograma, base estatística, baseado em LBP e métodos baseados em Fractal e que a maioria dos trabalhos em classificação de texturas utilizou classificadores como o KNN e os classificadores baseados em SVM.

([KAYA et al., 2015](#)) apresentaram dois novos descritores com o objetivo de encontrar diferentes padrões em imagens construídas sobre o descritor de textura LBP. Segundo os autores, o LBP apesar de ser um descritor estaticamente eficaz e ter aplicações bem-sucedidas na classificação de texturas, tem a desvantagem de procurar texturas predefinidas. Com isso, podendo não detectar as texturas em casos especiais. Então, com finalidade de melhorar, os autores propuseram dois descritores, um que é baseado nas relações entre os vizinhos sequenciais de um pixel central com uma distância específica e o outro, que é baseado na determinação dos vizinhos na mesma orientação através do parâmetro central pixel. Por fim, os autores aplicaram esses descritores em quatro tipos de bases e compararam com a aplicação do LBP tradicional. Com os resultados atingidos, os autores chegaram a conclusão que descritores propostos podem ser utilizados no processamento de imagens, já que os resultados mostram que as previsões obtidas por eles estavam em um intervalo aceitável.

Diante das propostas estudadas e apresentadas nos parágrafos acima, percebe-se o quanto métodos de classificação de textura são utilizados para classificar imagens de séries temporais. Os trabalhos a seguir utilizam dessas técnicas para solucionar problemas importantes, como na área de saúde e outros problemas.

([G.CASTELLANO et al., 2004](#)) propõem mostrar que a análise de parâmetros de textura é bastante adequada para aumentar as informações obtidas a partir de imagens médicas. Segundo os autores, imagens de ressonância magnética (RM) não são capazes de fornecer informações microscópicas que possam ser avaliadas visualmente. Mas que seria possível extrair informações através da análise de textura das imagens de RM, já que alterações nos tecidos biológicos presentes em algumas doenças podem ocasionar mudanças de textura dessas imagens. Com isso, o artigo trata de esclarecer os princípios da análise de textura através das principais categorias de

parâmetros de textura que são utilizadas para realizar essa análise e suas aplicações. As categorias descritas neste trabalho foram: Histograma, Gradiente absoluto, Matriz de comprimento total, Matriz de Coocorrência, Modelo auto-regressivo e Wavelets. Por fim o artigo mostra diversos exemplos de usos de cada técnica e que a análise de textura pode ser aplicada a qualquer conjunto de regiões de imagem que possam ser diferenciadas por tal descrição. Porém, os autores relataram que apesar de se conseguir extrair informações adicional, a análise permanece limitada pela resolução restrita de imagens.

apium realizam uma avaliação sobre a utilização da análise de textura para automatizar o reconhecimento de amostras de pólen. Esse reconhecimento é importante para diversas situações, como a prevenção de reações alérgicas, análise climática ou apicultura, mas isso é uma tarefa extensa, pois é necessário que seja identificado cada grão de pólen através do microscópio. Dessa forma, o objetivo do artigo é automatizar esse reconhecimento, para isso os autores utilizaram quatro métodos diferentes para extrair as características de textura da imagem do pólen, que foram: filtros log-Gabor (LGF), LBP, GLCM, e momentos discretos de Tchebichef (DTM). Após aplicação desses métodos para extrair as características da textura das imagens, foi utilizado o algoritmo K-ésimo Vizinho mais Próximo (K-NN) com a finalidade de diminuir o tamanho do vetor de características e também realizar a classificação. Por fim, os resultados mostraram que os métodos LGF e DTM obtiveram resultados melhores do que os demais. Apesar disso, os autores descobriram que a combinação de todos os vetores de características extraídos através de todos os métodos, resultou em um maior desempenho e uma precisão de cerca de 95%.

([FISSEHA et al., 2015](#)) propõem facilitar o processo de diagnóstico de tumores, através da análise de textura de imagens. Segundo os autores, os diagnósticos de tumores nos pacientes podem ser realizados através de uma ferramenta poderosa, a microscopia de espalhamento Raman anti - Stokes (CARS). Essa ferramenta é bastante eficiente para visualização da composição molecular do tecido, sem a necessidade de qualquer coloração externa, o que permite imagens não invasivas de alta resolução. Apesar de ser uma ótima ferramenta, os autores propuseram um método para facilitar esses diagnósticos. O método consiste na classificação de forma automatizada das áreas saudáveis e tumorais em imagens CARS retiradas de amostras de pele. Este método é baseado na extração de características da textura das imagens, através da GLCM e LBP. A partir das características obtidas, o método realiza a classificação através da rede neural perceptron. Por fim, com a aplicação do método proposto na base de imagens, os autores concluíram que entre todas as classes de descritores, as características da textura extraídas pelo LBP tiveram a melhor sensibilidade e especificidade da classificação (88 e 91%, respectivamente), que é maior do que em uma abordagem previamente relatada para a classificação de imagens do CARS, o que se

torna um grande passo para o procedimento automatizado de detecção de tumores.

([MOHAMED et al., 2017](#)) apresentam uma abordagem de super-resolução que explora as informações complementares fornecidas por várias imagens do mesmo alvo, ao invés dos métodos convencionais que geralmente utilizam apenas uma imagem para extrair informações. Isso com a objetivo de melhorar o desempenho dos métodos de análise de textura quando aplicado à classificação de tumores em imagens de ultrassom de mama. Para isso, os autores propõem um sistema que consiste em quatro etapas: computação de super-resolução, extração da região de interesse, extração e classificação de recursos. E dessa forma, avaliaram cinco métodos de textura com o sistema proposto: características da GLCM, LBP, padrão binário local baseado em congruência de fase, histograma de gradientes orientados e espectro de lacunaridade padrão. Com a aplicação desses métodos, os autores chegaram a conclusão que os resultados obtidos mostram que a abordagem melhora o desempenho dos métodos de textura avaliados, superando o estado da arte na classificação de tumores.

([PHAM, 2018](#)) propõe uma abordagem para analisar pacientes neurodegenerativos e encontrar padrões para obter informações sobre doenças como Parkinson, Huntington e esclerose lateral amiotrófica. É bastante comum que essas doenças afetem a marcha e mobilidade do paciente, então é importante quantificar com precisão a dinâmica da marcha. Segundo o autor, a anormalidade da marcha é um desvio da marcha normal, e a observação do padrão da caminhada do paciente é considerada a parte mais importante da avaliação neurológica. Para isto, os métodos convencionais realizam extrações de informações através de séries temporais baseadas na análise de sinais 1-D. Já o método proposto pelo autor, tem como diferencial a transformação das séries temporais em imagens, das quais é possível extrair características através da análise da textura das imagens. Dessa forma, a transformação das séries temporais de marcha em imagens é realizada através do algoritmo Fuzzy, onde é possível extrair informações utilizando, métodos de análise de textura, para classificar padrões. Para isto, ele utilizou o método GLCM e o classificador LSSVM para diferenciar os pacientes com o controle saudável dos demais com as doenças. Por fim, segundo o autor, os resultados dos seus experimentos indicam que o método proposto fornece os melhores resultados, comparando com vários outros métodos para classificar padrões de dinâmica de marcha relacionada as doenças de Parkinson, Huntington e esclerose lateral amiotrófica.

([RAJEANDRA et al., 2013](#)) apresentam uma técnica para automatizar a classificação de sinais EEG, que são utilizados para estudar as características das crises epiléticas. O trabalho relata que esses sinais são bastantes complexos e as mudanças são difíceis de decifrar por causa da sua pequena amplitude e sua natureza aleatória, o que torna difícil de diagnosticar a olho nu. Com o objetivo de amenizar a comple-

xidade e auxiliar o diagnóstico de forma automatizada, é sugerida uma solução para ser usada, como um software de monitoramento automático de crises nos pacientes. Essa solução consiste em uma técnica que utiliza o algoritmo Transformada Wavelet Contínua (CWT) para transformar os sinais do EEG em um gráfico CWT, do qual, são extraídos os recursos de Espectros de ordem superior (HOS) e texturas. Para isso, ele utilizou algoritmos de textura como Matriz de co-ocorrência de níveis de cinza (GCLM), LBP, Matriz de Comprimento de Execução de Nível Cinza (GLRM). Dessa forma, os recursos obtidos são acoplados a classificadores como Árvore de Decisão (DT), KNN, a Rede Neural Probabilística (PNN) e o SVM com finalidade de classificar os sinais EEG em classes normais, interictais e ictais e assim poder diagnosticar os estados dos pacientes. Por fim, o artigo apresenta bons resultados, porém, como relatam os autores, melhores resultados podem se alcançados explorando mais dados EEG e analisando classificadores mais robustos.

4 Classificação de imagens de texturas de epilepsia

A classificação de imagens por meio de padrões é um dos processos mais complexos em processamentos de imagens digitais. Métodos diferentes são utilizados com o objetivo de extrair dados para serem usados em diferentes domínios de aplicações, como o método de investigação para diagnósticos por imagens. As informações são extraídas dos padrões existentes em uma imagem podem auxiliar na tomada de decisões em diversas áreas. Os padrões de textura encontrados em imagens possuem informações sobre a distribuição espacial, luminosidade e arranjo estrutural da superfície em relação às regiões vizinhas e a textura é uma das características mais importantes para classificar e reconhecer objetos e cenas, e pode ser caracterizada por variações locais em valores de pixels que se repetem de maneira regular ou aleatória ao longo do objeto ou imagem. Dessa forma, este trabalho visa classificar imagens resultante do Gráfico de Recorrências através da análise de textura, seguindo as seguintes etapas apresentadas na Figura 11.

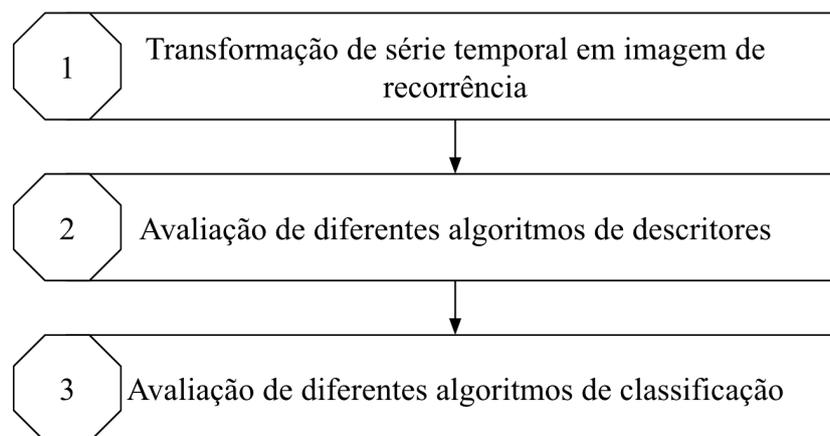


Figura 11 – Etapas de classificação de imagens de texturas de epilepsia.

Fonte – Do Autor

4.1 Transformação de serie temporal em imagem de recorrência

O exame EEG é utilizado para monitorar e registrar a atividade elétrica do cérebro para detectar possíveis anormalidades e assim diagnosticar doenças como a epilepsia. O exame é apresentado por um gráfico de séries temporais extraídas de

exames EEG disponibilizados no artigo (ANDRZEJAK et al., 2002). As séries temporais são estudadas na área de análise de séries temporais, que disponibiliza diversas ferramentas para extração de informação dessas séries. Uma delas é o Gráfico de Recorrência, que usualmente é utilizada para verificar a mudança de um padrão no sinal. Por exemplo, se uma pessoa está de olho aberto, espera-se um padrão de resposta no exame EEG diferente do padrão de resposta de quando o paciente está com um ataque epilético. Nesse trabalho, iremos analisar o padrão de textura das imagens definidas por Gráficos de Recorrências para diferenciar pacientes saudáveis de olhos abertos e com ataque epilético.

A construção das imagens definidas por Gráficos de Recorrências passa por duas etapas. Essas imagens apresentam a dissimilaridade entre dois pontos do espaço de fase do sinal. Então, a primeira etapa é encontrar a dimensão desse espaço. Entre diversos métodos para estimação da dimensão do espaço de fase, utilizamos o algoritmo de falsos vizinhos próximos (CARL; RHODES, 1997), que explicando de forma simples, o método avalia a alteração das distância entre os estados do espaço de fase considerando incrementos das dimensão. A saturação dessa alteração entre dimensões consecutivas sugere uma dimensão apropriada. A dimensão usual para esses estados é 3, pois quando essa dimensão aumenta pra mais que 3, essa alteração das distâncias se torna muito pequena. A segunda etapa é a definição da defasagem da fase do sinal, ou *Tau* (τ). A defasagem (τ) é encontrada através do algoritmo de informação mútua (MARTINERIE, 1992). Esse algoritmo retorna como resposta a quantidade de posições que serão saltadas no eixo do tempo (t) do sinal.

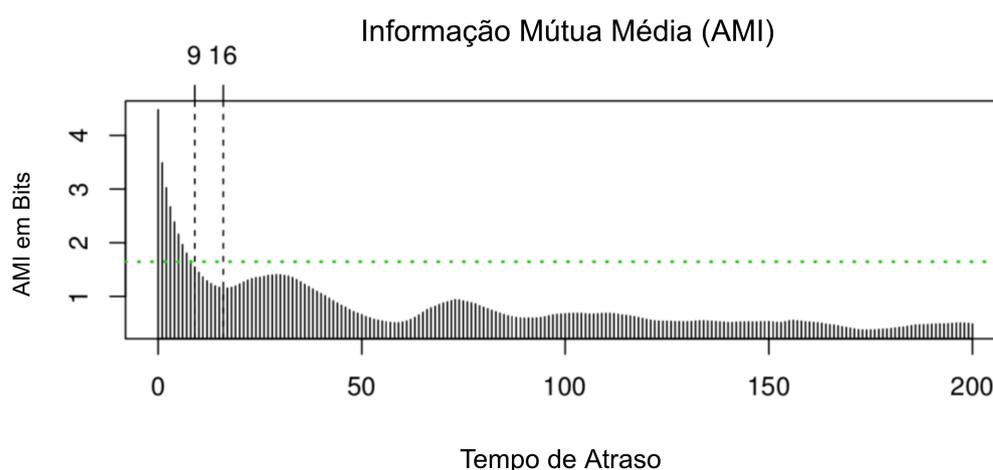


Figura 12 – Estimação do tempo de defasagem por meio da função de informação mútua.

Fonte – Do autor.

A Figura 12 apresenta o gráfico da função de informação mútua para estimação do parâmetro (τ) com 200 defasagens da série temporal. A primeira linha representa à estimação por meio do limiar do decaimento exponencial com valor 9 e a segunda representa o primeiro mínimo local com valor 16, são dois métodos utilizados para escolher o valor de (τ) através da informação mútua.

No final, a imagem é gerada contendo a matriz de dissimilaridade entre todos os pontos gerados a partir das etapas explicadas anteriormente. Em nossa base de dados, as imagens apresentam 90% de 4096 pontos adquiridos, então a imagem forma uma matriz simétrica contendo a distância entre pares dos 3.684 pontos

4.2 Avaliação de diferentes algoritmos de descritores

A classificação automática de imagens de séries temporais depende fortemente da representação de imagens. Esta representação pode ser obtidas usando descritores, que quando aplicados é possível obter valores que representam características como forma, curvas, cor, textura e medidas estatísticas da imagem. Neste trabalho, foram escolhidos descritores de análise de textura que representam os recursos com eficiência, possibilitando maior precisão na classificação. A maioria dos descritores de textura são simples e baseados em orientações, arranjos espaciais de pixels, uniformidade, histograma e gradientes. Por esse motivo e pelo fato de seu uso em trabalhos clássicos da literatura ou trabalhos mais recentes envolvendo a tarefa de classificar imagens em séries temporais, foram escolhidos os descritores: LPB, LPQ e o banco de filtros de Gabor. A Figura 13 mostra o processo para extrair as características das imagens neste trabalho. As imagens da base de dados serve como entrada para a aplicação dos descritores que extrai as características e representam em forma de vetores. A quantidade e valores do vetor obtido varia de acordo com cada descritor.



Figura 13 – Processo de extração de características.

Fonte – Do Autor.

Na tarefa de avaliar esses descritores e obter melhores resultados, este trabalho aplicou variâncias nos parâmetros de cada descritor de acordo como foi apresentado

no capítulo 2, estes descritores necessitam de parâmetros de entrada, de forma que a alteração desses parâmetros podem sofrer modificações de acordo com características do problema analisado. No capítulo 5 serão apresentadas quais as variações e quais métodos foram aplicados para selecionar cada um desses parâmetros. Além de analisar individualmente cada descritor, também foi realizada uma análise combinando os descritores entre si. Esta combinação foi realizada com a junção dos resultados dos vetores de características de cada descritor, combinação dos vetores do LBP com o LPQ, do LPQ com o GFB e por fim o junção dos três LBP, LPQ e o GFB.

4.3 Avaliação de diferentes algoritmos de classificação

Um dos principais objetivos dos algoritmos de classificação é usar vetores de características gerados do objeto analisado para identificar a qual classe ou categoria ele pertence. Os algoritmos de classificação são utilizados neste trabalho para classificar as imagens de recorrência no problema de pessoas sofrendo ataques epiléticos ou apenas com olho aberto. Os classificadores utilizados foram o SVM e o *Random Forest*. O SVM tem como objetivo encontrar um hiperplano com máxima separação entre as classes, ou caso os dados não forem lineares, mapear os dados usando a função *kernel* em um espaço de características de dimensão mais elevada onde os dados se tornam linearmente separáveis. E o *Random Forest* utiliza o método de árvores de decisão que possibilita a exploração de uma grande quantidade de dados de entrada, ele é um classificador de árvores de classificação. Um dos principais fatores para a escolha desses algoritmos foi com base em outros trabalhos de análise de textura (DUARTE et al., 2014; SOUZA; SILVA; BATISTA, 2014; SILVA et al., 2018), que apresentaram ótimos resultados na literatura.

A Figura 14 mostra o processo de classificação das imagens neste trabalho. Os vetores de características obtidos a partir da aplicação dos descritores servem de entrada para os algoritmos de classificação o SVM e o *Random Forest*, obtendo assim os resultados de cada classe, pacientes com olhos abertos e com ataque epilético.



Figura 14 – Processo de classificação.

Fonte – Do Autor.

Por fim, o objetivo deste trabalho é desenvolver um estudo de classificação de imagens de textura geradas por Gráficos de Recorrência no problema pessoas sofrendo ataques epiléticos e tem como principal motivação que nenhum outro estudo, segundo o conhecimento dos autores, apresentou um sistema ou análise sobre esse tipo de classificação com a análise de textura.

5 Análise Experimental

Este capítulo descreve brevemente a metodologia utilizada no desenvolvimento do trabalho para a análise de descritores de textura e dos algoritmos de classificação em imagens de recorrência. As etapas tratam do ambiente experimental utilizado, da construção da base de dados, da análise dos parâmetros dos algoritmos e por fim o método de avaliação empregado na análise dos experimentos.

5.1 Ambiente Experimental

O ambiente utilizado para análise das imagens do trabalho foram desenvolvidos utilizando a linguagem de programação Python 2.7.16, o ambiente de desenvolvimento PyCharm CE e para classificação o Weka (HALL et al., 2009). Abaixo segue o que foi utilizado para cada etapa da pesquisa:

- Para criar os vetores para classificação, utilizando os descritores LBP, LPQ e Banco de Filtros de Gabor, foi utilizada a biblioteca Scikit-learn. Essa biblioteca é gratuita e possui soluções de aprendizagem de máquina para Python (PEDREGOSA et al., 2011).
- O ambiente PyCharm CE foi utilizado para implementar os descritores e gerar os arquivos com extensão csv usados como entrada para classificação da base.
- Na avaliação dos classificadores, *Random Forest* e SVM foi utilizado o software Weka (*Waikato Environment for Knowledge Analysis*) (HALL et al., 2009), que possui vários algoritmos implementados para o uso, como os classificadores utilizados nesse trabalho.

5.2 Construção da Base de Dados

A base de dados utilizada neste trabalho é formada por registros de eletroencefalogramas de pessoas com ou sem epilepsia, transformados em Gráficos de recorrência. Os exames EEG disponibilizados no artigo (ANDRZEJAK et al., 2002) demonstram vários estados de cinco pessoas saudáveis e cinco pessoas com epilepsia. Os exames EEG de pessoas com epilepsia foram registrados durante a atividade epilética de convulsão. Nesse trabalho foram escolhidas as amostras de pessoas saudáveis (com olhos abertos) e pessoas em estado epilético. As imagens transformadas contêm

a matriz de dissimilaridade entre todos os pontos gerados a partir da obtenção da dimensão desse ponto e a definição da defasagem. Na base de dados deste trabalho, as imagens apresentam 90% de 4096 pontos adquiridos, então a imagem forma uma matriz simétrica contendo a distância entre pares dos 3.684 pontos. A base de dados contém 100 imagens de classe S que representa pessoas em ataques epiléticos e 100 imagens de classe F que representa pessoas de olhos abertos, ou seja, saudáveis.

Como as imagens possuem uma escala para representar as distâncias normalizadas entre os estados do espaço de fase construído, foi necessário realizar um recorte automático para manter apenas a parte de interesse para este trabalho e evitar possíveis ruídos. A resolução das imagens originais são fixas, contendo 1200×900 pixels, depois da operação de recorte, a resolução das imagens finais ficaram com 736×734 pixels. A Figura 15a apresenta um exemplo de uma imagem original e a Figura 15b apresenta o resultado após o recorte.

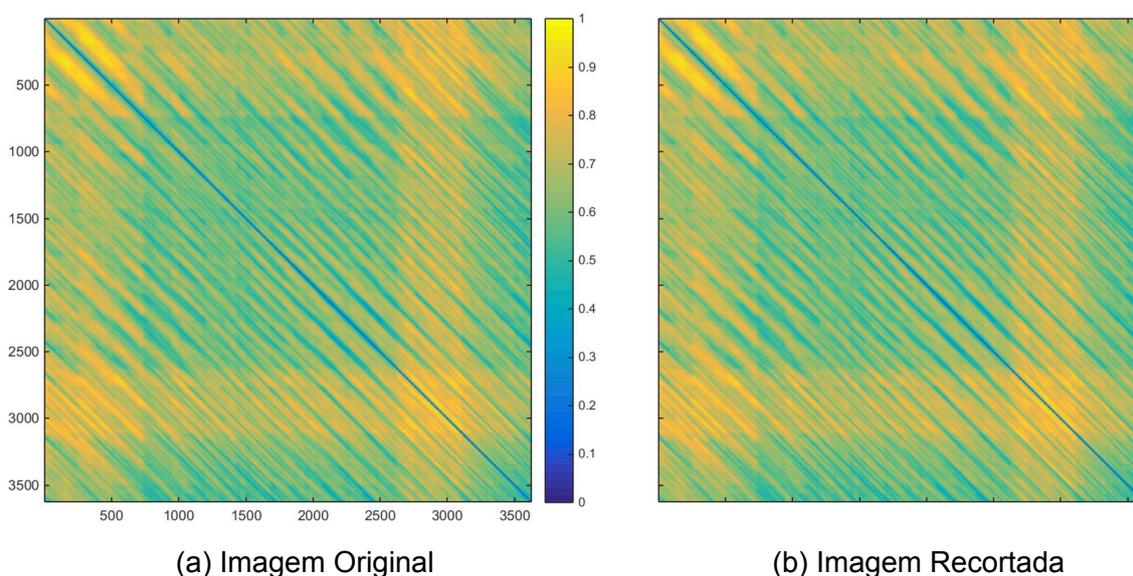


Figura 15 – Imagens da base de dados

Fonte – Do autor

5.3 Análise dos Parâmetros

Os descritores de textura são utilizados para obter informações a partir da extração das características da textura de imagens. A classificação de textura tem como objetivo encontrar um descritor de textura que seja eficiente e discriminativo. Nessa etapa do trabalho foram escolhidas as técnicas LBP, LPQ e Banco de Filtros de Gabor (GFB), que segundo a literatura, apresentaram ótimos resultados para análise de textura (SOUZA; SILVA; BATISTA, 2014; MASOOD et al., 2016; PHILOMINA; SIMON, 2018; KAYA et al., 2015; RAJEANDRA et al., 2013; VICTOR MARCOS A et al., 2015).

Essas técnicas são utilizadas para medir similaridade entre texturas descritas por códigos binários locais, que serão transformados em vetores de características.

5.3.1 Padrão Binário Local (*LBP*)

O LBP é calculado a partir de um conjunto de pontos (P) igualmente espaçados e distribuídos dentro de uma circunferência de raio (R) com centro sobre um pixel fixo, como ilustrado na Figura 16.

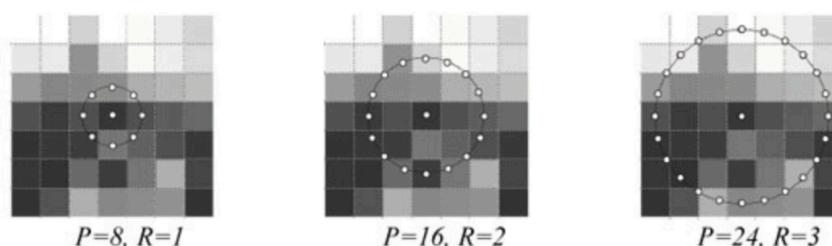


Figura 16 – Representação para diferentes valores de P e R

Fonte – MARCELO et al.

A partir da intensidade de cada um desses pontos e da intensidade do pixel central é obtido uma sequência de valores binários. Segundo (BRAHNAM et al., 2010) os valores dos parâmetros P e R no LBP têm impacto sobre a acurácia da classificação. Os valores ótimos destes parâmetros estão relacionados às dimensões das estruturas periódicas que, em última análise, caracterizam as texturas presentes na imagem. Por esse motivo, os parâmetros P e R foram variados com objetivo de encontrar valores ótimos para as imagens utilizadas neste trabalho. Com base nos artigos (MARCELO et al., 2011; LUIZ et al., 2015), os valores dos parâmetros atribuídos para o LBP estão listados abaixo:

Tabela 1 – Combinação de valores dos parâmetros R e P para o LBP

Combinação	R	P
1	3	24
2	1	4
3	1	8
4	1.5	12
5	2	16

5.3.2 Quantização de Fase Local (*LPQ*)

O descritor de textura LPQ é capaz de produzir códigos que são insensíveis ao desfoque de imagem. Aplicado para identificar características da textura, o código é calculado para cada pixel da imagem usando um tamanho de janela $M \times M$, onde

são computadas informações localmente em qualquer posição do pixel da imagem. Com isso, é apresentado os códigos resultantes como um histograma que é utilizado como recursos para a classificação de textura (Dawood; Dawood; Guo, 2012). Neste trabalho, como forma de maximizar os resultados, os experimentos com o LPQ foram executados com variações dos parâmetros Raio R e Frequência F . De acordo com a documentação do Mathworks, R deve ser um número ímpar e maior ou igual a 3 e F indica qual método é usado para a estimativa de frequência local. Os possíveis valores são:

- $F = 1$ que indica o uso da transformada de Fourier de curto prazo (STFT) com a janela uniforme (corresponde à versão básica do LPQ).
- $F = 2$ que indica o uso de STFT com a janela gaussiana.
- $F = 3$ que indica o uso de par de filtros quadrados da derivada da gaussiana.

Com base nessas informações, este trabalho utilizou as seguintes variações de parâmetros do LPQ:

Tabela 2 – Combinação de valores dos parâmetros R e F para o LPQ

Combinação	R	F
1	5	1
2	5	2
3	5	3
4	7	1
5	7	2
6	7	3
7	9	1
8	9	2
9	9	3

5.3.3 Bancos de Filtros de Gabor (*GFB*)

O GFB é bastante utilizado para análise de textura através da criação de um banco de filtros de Gabor, com N escalas e X direções, onde é filtrada a imagem de entrada com cada um dos filtros, construindo um vetor de características a partir de cada imagem filtrada. Neste trabalho o cálculo dos descritores foram obtidos a partir de momentos estatísticos como a média e a variância. Para gerar o filtro é necessário integrar sobre as n escalas e x direções variando o ângulo (θ), a frequência (F) e o valor sigma (S) do envelope gaussiano. Por tanto neste trabalho, os parâmetros foram variados de acordo com as etapas a seguir:

- Etapa 1: O θ foi variado de 1 até 4 e aplicado a fórmula a seguir para obter valores variados de θ .

$$\theta = \frac{\theta}{4 * \pi} \quad (5.1)$$

- Etapa 2: Os valores de S foi variado de forma crescente e os de F foram fixados nos valores padrões intercalando entre 0.05 ou 5, demonstrados na Tabela 3 a seguir:

Tabela 3 – Combinação da etapa 2 dos valores dos parâmetros S e F para o GFB

Combinação	S	F
1	(1 ou 2)	(0.05 ou 5)
2	(1 ou 3)	(0.05 ou 5)
3	(1 ou 4)	(0.05 ou 5)
4	(1 ou 5)	(0.05 ou 5)
5	(1 ou 6)	(0.05 ou 5)

- Etapa 3: Os valores de S foram fixado nos valores padrões intercalando entre 1 ou 5 e os de F foram variados de forma crescente, demonstrado na Tabela 3 a seguir:

Tabela 4 – Combinação da etapa 3 dos valores dos parâmetros S e F para o GFB

Combinação	S	F
1	(1 ou 5)	(0.05 ou 1)
2	(1 ou 5)	(0.05 ou 1.5)
3	(1 ou 5)	(0.05 ou 2)
4	(1 ou 5)	(0.05 ou 2.5)
5	(1 ou 5)	(0.05 ou 3)
6	(1 ou 5)	(0.05 ou 3.5)
7	(1 ou 5)	(0.05 ou 4)
8	(1 ou 5)	(0.05 ou 4.5)

5.4 Avaliação dos Experimentos

Neste trabalho o método utilizado para avaliar os experimentos foi a validação cruzada, que é uma técnica para avaliar modelos preditivos particionando a amostra original em um conjunto de treinamento para treinar o modelo e um conjunto de testes para avaliá-lo. O conjunto original dos vetores de características foi dividida aleatoriamente em 10 subconjuntos de tamanho iguais. Dos 10, apenas um é retirado como dados de teste para avaliar o modelo, e as outros subconjuntos restantes foram utilizados como dados de treinamento. Esse passo é repetido para cada subconjunto, até que cada subconjunto tenha ido para o conjunto de teste.

Os algoritmos de classificação SVM e RFT foram executados com a validação cruzada repetida por cinco vezes, onde em cada execução os vetores eram distribuídos de formas aleatórias, dessa maneira foram adquiridas cinco taxas de acertos, precisão, recall e F-Measure calculando assim a taxa média de acerto dos algoritmos, taxa média de precisão, recall e F-Measure .

Em seguida, as configurações de parâmetros de cada descritores que obtiveram a maior taxa média de acertos foram combinados entre si, demonstrado na Tabela 5. A partir disso foram classificados utilizando os mesmos métodos e algoritmos como na etapa anterior.

Tabela 5 – Melhores resultados

Descritores	Classificador
LBP E LPQ	SVM
LBP E LPQ	RF
GFB e LPQ	SVM
GFB e LPQ	RFT
LBP, GFB, LPQ	SVM
LBP, GFB, LPQ	RFT

Por fim, para verificar se o método apresentado nesse trabalho tem boa aceitação clínica avaliando o critério estabelecido no artigo de referência (NUWER, 1997) foi calculada a taxa de sensibilidade com o resultado que obteve a maior média de taxa de acertos. A taxa de sensibilidade tem como fórmula:

$$sensibilidade = \frac{VP}{VP + FN} \quad (5.2)$$

Onde VP significa Verdadeiro Positivo e FN Falso Negativo.

6 Resultados

Neste capítulo serão apresentados os resultados obtidos a partir da aplicação dos descritores e dos classificadores definidos no Capítulo 5 nas imagens de recorrência geradas a partir de leituras do exame EEG, de ataques epiléticos. A métrica de avaliação de desempenho utilizada é a acurácia da classificação, que é dada pela razão entre o número de acertos e o número total de amostras. A seguir são apresentados os resultados dos descritores Padrão Binário Local (LPB), Quantização de Fase Local (LPQ) e Bancos de Filtros de Gabor (GFB), classificados pelos algoritmos Máquina de Vetores de Suporte (SVM) e Floresta Aleatória (RFT).

A Tabela 6 apresenta a porcentagem da acurácia dos 10 Experimentos (EXP), e a média de acerto, a média de precisão, a média de recall e a média de F-measure. Estes resultados foram obtidos a partir da utilização do descritor LBP e a variação dos seus parâmetros, o Raio (R) e a quantidade de pontos (P) conforme explicado na Subseção 5.3.1. O melhor resultado é destacado em negrito.

Tabela 6 – Experimentos utilizando o Descritor LBP

EXP	Classificador	Parâmetros		Média Acerto	Precisão	Recall	F-Measure
		R	P				
1	SVM	3	24	83,5	84	83,5	83,4
2	RFT	3	24	84,6	84,7	84,6	84,6
3	SVM	1	4	73	68	73,8	73,7
4	RFT	1	4	80	74	78	77,7
5	SVM	1	8	75	73	72,6	72,4
6	RFT	1	8	81	80	80	80
7	SVM	1.5	12	74	75	75	75
8	RFT	1.5	12	78	81,2	81	81
9	SVM	2	16	81	81,6	81,3	81,3
10	RFT	2	16	84	84	84	84

Com base nos resultados apresentados na Tabela 6, o melhor resultado foi obtido com o classificador RFT com média de acerto 84,6%, precisão 84,7%, recall e da F-Measure com 84,6% usando $R = 3$ e $P = 24$. Apesar disso é possível observar que para esses parâmetros, utilizando o SVM, o resultado ficou próximo variando entre 83% e 84%. Ainda assim, o RFT em todos os resultados das métricas dos experimentos aplicados conseguiu atingir os melhores resultados. Além disso, o LBP atingiu a menor taxa média de acertos com 73%, precisão 68%, recall 72.6% e F-Measure com 72,4% de todos os experimentos executados neste trabalho, utilizando o classificador SVM.

A Tabela 7 estão os resultados obtidos para a classificação do descritor LPQ por meio das técnicas SVM e RFT. Foram realizados 18 experimentos, variando os valores

dos parâmetros de Raio (R) e Frequência (F), conforme a Subseção 5.3.2, mostrando média total de acerto, precisão, recall e F-Measure resultante de cinco execuções dos 18 experimentos. O melhor resultado é destacado em negrito.

Tabela 7 – Experimentos utilizando o Descritor LPQ

EXP	Classificador	Parâmetros		Média Acerto	Precisão	Recall	F-Measure
		R	F				
1	SVM	5	1	90,2	90,2	90,2	90,2
2	RFT	5	1	85,8	84,7	85,2	85,2
1	SVM	5	2	90,2	90,2	90,2	90,2
4	RFT	5	2	85,8	84,7	85,2	85,2
1	SVM	5	3	90,2	90,2	90,2	90,2
6	RFT	5	3	85,8	84,7	85,2	85,2
7	SVM	7	1	88,7	89,6	89,5	89,5
8	RFT	7	1	84,8	85,14	84,8	84,8
9	SVM	7	2	88,7	89,6	89,5	89,5
10	RFT	7	2	84,8	85,14	84,8	84,8
11	SVM	7	3	88,7	89,6	89,5	89,5
12	RFT	7	3	84,8	85,14	84,8	84,8
13	SVM	9	1	92,1	92,26	92,1	92,1
14	RFT	9	1	90,1	90,28	90,1	90,1
15	SVM	9	1	92,1	92,26	92,1	92,1
16	RFT	9	2	90,1	90,28	90,1	90,1
17	SVM	9	1	92,1	92,26	92,1	92,1
18	RFT	9	3	90,1	90,28	90,1	90,1

Segundo os resultados obtidos, é possível observar que a melhor média da acurácia, precisão, recall e F-measure foram para os parâmetros de $R = 9$, $F = 1$, $F = 2$ e $F = 3$ com 92,1%, 92,26%, 92,1% e 92,1%, respectivamente, utilizando o classificador SVM. Além disso, os mesmos parâmetros também foram responsáveis para adquirir o melhor resultado para todas as métricas utilizando o classificador RFT. Apesar da proximidade dos resultados entre os classificadores, em todos os 18 experimentos o classificador SVM conseguiu atingir a média da taxa de acertos, precisão, recall e F-measure superior ao RFT. Bem como, para os parâmetros $R = 7$, $F = 1$, $F = 2$ e $F = 3$ o LPQ obteve seus menores resultados utilizando o classificador RFT, a taxa média de acerto, recall e F-measure obterem o resultado de 84.8% e para precisão seu menor valor foi de 84.7% com os parâmetros $R = 5$, $F = 1$, $F = 2$ e $F = 3$. Uma observação importante que foi verificado nos experimentos, é que a variação de F não influenciou em nenhum dos resultados.

Em seguida, a Tabela 8 apresenta os resultados dos experimentos utilizando o descritor GFB e os classificadores propostos neste trabalho. Foram realizados 24 experimentos conforme explicado na Subseção 5.3.3, e executados cada um 5 vezes para obter a média de acertos, precisão, recall e F-measure. Foram utilizados parâmetros como o ângulo (θ), que varia de 1 até 4, aplicando a fórmula apresentada na Subseção 5.3.3. Como não houve alteração da variação de 1 até 4 nos experimentos,

os valores de θ não estão inclusos na Tabela 8. Os parâmetros S e F que possuem valores intercaláveis, estão apresentados com a notação $p = (x, y)$, sendo p o parâmetro, x o primeiro valor e y o segundo valor intercalado. Os melhores resultados estão destacados em negrito.

Observando a Tabela 8, pode-se analisar que os parâmetros $S = (1, 3)$ e $F = (0, 0.5 \text{ e } 5)$, mostraram as maiores taxas médias de acerto, recall e f-measure com 88,5% e precisão com 88,6% utilizando o classificador SVM.

Tabela 8 – Experimentos utilizando o Banco de Filtros de Gabor

EXP	Classificador	Parâmetros		Média Acerto	Precisão	Recall	F-Measure
		S	F				
1	SVM	1 - 2	0,05 - 5	85,8	85,9	85,8	85,8
2	RFT	1 - 2	0,05 - 5	87,8	87,9	87,9	87,9
3	SVM	1 - 3	0,05 - 5	88,5	88,6	88,5	88,5
4	RFT	1 - 3	0,05 - 5	88,2	88,5	87,7	86,4
5	SVM	1 - 4	0,05 - 5	86,3	86,4	86,3	86,3
6	RFT	1 - 4	0,05 - 5	86,7	86,7	86,7	86,7
7	SVM	1 - 5	0,05 - 5	85,9	75,8	75,6	75,7
8	RFT	1 - 5	0,05 - 5	86,8	81,46	80,8	80,7
9	SVM	1 - 5	0,05 - 1	74,1	74,5	74,1	74
10	RFT	1 - 5	0,05 - 1	80,5	80,9	80,5	80,42
11	SVM	1 - 5	0,05 - 1.5	75,6	75,6	75,6	75,5
12	RFT	1 - 5	0,05 - 1.5	80,8	81,46	80,8	80,7
13	SVM	1 - 5	0,05 - 2	77,5	77,9	77,7	77,62
14	RFT	1 - 5	0,05 - 2	84	84,2	84	84
15	SVM	1 - 5	0,05 - 2.5	88	88,1	88,2	88,2
16	RFT	1 - 5	0,05 - 2.5	88	88,1	88,2	88,2
17	SVM	1 - 5	0,05 - 3	79,4	80	80,1	80,1
18	RFT	1 - 5	0,05 - 3	82,4	82,6	82,4	82,4
19	SVM	1 - 5	0,05 - 3.5	84,9	85	84,9	84,9
20	RFT	1 - 5	0,05 - 3.5	84,3	84,7	84,6	84,6
21	SVM	1 - 5	0,05 - 4	80,6	81,2	80,6	80,6
22	RFT	1 - 5	0,05 - 4	84,5	84,7	84,7	84,7
23	SVM	1 - 5	0,05 - 4.5	76,2	76,8	77	77
24	RFT	1 - 5	0,05 - 4.5	81,8	82	82,6	82,4

A partir dos resultados obtidos nos experimentos apresentados nas Tabelas 6, 7 e 8, foram realizadas combinações entre os descritores que tiveram as maiores taxas médias de acerto. A Tabela 9 apresenta os resultados dessas combinações.

Tabela 9 – Experimentos das combinações dos melhores resultados

EXP	Classificador	Média Acerto
LBP E LPQ	SVM	82,3
LBP E LPQ	RFT	87
GFB e LPQ	SVM	82
GFB e LPQ	RFT	87
LBP, GFB, LPQ	SVM	82,4
LBP, GFB, LPQ	RFT	87,7

O melhor resultado obtido dentre todas as combinações realizadas foi com os três descritores LBP, GFB e LPQ, utilizando o classificador RFT. Essa execução retornou 87,7% de média de taxa de acerto. Além disso, pode-se observar que a combinação do LBP com LPQ e LPQ com o GFB apresentaram 87% de taxa média de acerto, valor próximo do maior resultado obtido.

Seguindo a análise, a Tabela 10 apresenta os resultados da média de tempo com base em cinco execuções para calcular os descritores aplicados na base de imagens deste trabalho. O LBP leva o menor tempo, sendo 38,2 segundos. Já o GFB durou 47 minutos e 41 segundos para executar a mesma atividade, cerca de 80 vezes maior em relação ao LBP. O LPQ apresentou tempo médio de execução de 5 minutos e 59 segundos, e obteve um tempo entre os descritores LBP e GFB.

Tabela 10 – Tempo médio para coleta dos Descritores

Descritores	Tempo Médio
LBP	38.2s
LBQ	5 min 59s
GFB	47 min 41 s

Além disso, conforme apresentado em (NUWER, 1997), que utilizou o cálculo de sensibilidade para determinar a viabilidade de algoritmos computacionais junto exames EEG, o melhor resultado obtido neste trabalho foi analisado para se obter o valor da sensibilidade. Dessa forma foi utilizado a matriz de confusão do LPQ que atingiu a maior taxa média de acerto. A Tabela 11 representa a Matriz de confusão que mostra as frequências de classificação para cada classe do modelo. A classe F representa pessoas sem epilepsia e a S pessoas com epilepsia.

Tabela 11 – Matriz de confusão

Classe	Predição	
	F	S
F	95	5
S	10	90

A Tabela 11 mostra que para S o algoritmo acertou 90 imagens (verdadeiro positivo - VP) e 10 imagens de pessoas com epilepsia classificadas erroneamente como F, ou seja falso negativo (FN). Para F, o algoritmo classificou corretamente que 95 imagens não tinham epilepsia (verdadeiro negativo - VN) e 5 imagens foram classificadas erroneamente com a existência da doença (falso positivo - FP). Com essas informações foi possível calcular a taxa de sensibilidade. Segundo (NUWER, 1997) são considerados aceitáveis os algoritmos na saúde com sensibilidade a cima de 80% e a taxa obtida neste trabalho foi 90%.

6.1 Discussão

Os experimentos realizados possuem objetivo de obter a acurácia, precisão, recall e f-measure dos descritores LBP, LPQ, GFB usando os algoritmos de classificação SVM e RFT, para que sejam avaliados na atividade de classificar imagens de textura geradas por imagens de recorrência dentro do problema de pessoas sofrendo ataques epiléticos.

Os experimentos mostraram que o descritor LBP, apesar de apresentar uma taxa média de tempo de execução com tempo menor que os outros descritores (38.2s), a sua maior taxa média de acerto, recall, f-measure foram de 84,6% e precisão com 84,%, usando o RFT, resultado que foi inferior aos obtidos pelos outros descritores. Além disso, considerando o algoritmo SVM, a taxa média de acertos, precisão, recall e f-measure também se manteve inferior aos outros experimentos, respectivamente, com 73%, 68%, 72.6% e 72.4%.

Dentre os experimentos usando o descritor GFB, a maior taxa média de acerto foi de 88,5% usando o classificador SVM, maior apenas do que o resultado obtido pelo descritor LBP. Considerando o classificador RFT, a taxa média de acerto, precisão, recall foram aproximadamente 88,2% e para precisão 88,6%. Porém, o seu tempo médio de execução foi cerca de 80 vezes a maior do que o tempo do LBP, atingindo assim o tempo médio de 47min e 41s.

Já o LPQ apresentou as maiores médias de acertos, precisão, recall e f-measure com 92,1%, 92,26% e 92,1%, 92,1, respectivamente, utilizando o classificador SVM. O seu tempo médio de execução foi superior ao GFB e inferior ao LBP, com 5min 59s. Uma observação importante que se pode notar na Tabela 7, é que a variação da frequência (F) não impactou nas métricas e que os valores obtidos usando o classificador SVM foram superiores aos valores com o o classificador RFT.

Com o objetivo de atingir um maior resultado que as acurácias já obtidas nos demais experimentos, este trabalho também aplicou a combinação dos melhores resultados dos descritores apresentados na Tabela 9. A combinação dos descritores LBP, LPQ e GFB mostraram uma taxa média de acerto de 87,7%. Comparando com os resultados da execução individual do LBP, GFB e LPQ, a combinação foi superior apenas a taxa média de acertos do LBP.

Como foi descrito no Capítulo 2, cada um desses descritores possuem características e particularidades que influenciam na classificação e análise de textura. Diante da discussão destes resultados, o descritor LPQ se destacou pela as maiores taxa médias das métricas estabelecidas neste trabalho, com 92,1% de taxa média de acertos, recall e f-measure e 92,26% de precisão, usando o classificador SVM com os parâmetros R igual a 9 e F sendo 1, 2 ou 3. Comparando se com os três descritores juntos

percebe-se assim, que o LPQ possui maior capacidade para representar as características das texturas das imagens analisadas neste trabalho.

7 Conclusão e trabalhos futuros

Este trabalho apresentou um estudo sobre extração de características em imagens através de descritores de texturas, além de algoritmos de aprendizagem de máquina para classificação de imagens de séries temporais baseadas em exames de EEG em pacientes com epilepsia. De acordo com bons resultados apresentados na literatura para problemas que envolvem análise de texturas, foram considerados os descritores LBP, LPQ e Banco de Filtros de Gabor. Para todos os experimentos realizados neste trabalho, uma base de dados de séries temporais baseadas em exames de EEG em pacientes com ou sem epilepsia com 200 imagens foi utilizada.

Para a execução dos descritores, foi realizada uma análise de parâmetros. Para o LBP, a análise foi feita com base em valores que se pode encontrar em trabalhos relacionados na literatura, tanto para o número de pontos (P) como para o valor do raio (R). Para o LPQ os parâmetros raio (R) e frequência (F) foram variados de acordo com a documentação do [Mathworks](#). Por fim, a análise dos parâmetros do Banco de Filtros de Gabor foi executada com base em um experimento subdividido em três etapas, a fim de selecionar valores que se destacaram. O resultado dos experimentos apresentaram bons resultados considerando os trabalhos relacionados apresentados na literatura. O LBP apresentou uma taxa média de tempo de execução (38,2s) superior aos outros descritores porém, a sua maior taxa média de acerto, recall e f-measure de 84,6% e precisão com 84,7%, utilizando o classificador Random Forest, foi inferior aos demais. Considerando o classificador SVM, a taxa média de acertos também se manteve inferior aos outros experimentos com 73%. A maior taxa média de acerto, recall e f-measure do GFB foi de 88,5% e a precisão de 88,6% usando o SVM, sendo maior do que o resultado do LBP. Considerando o Random Forest, a taxa média de acertos e precisão foram aproximadas com 88,2%. Apesar do bom resultado, o tempo médio de execução foi destacado negativamente por atingir um valor muito alto 47min e 41s. Por fim, o LPQ apresentou a maior média com todas as métricas estabelecidas neste trabalho, para a taxa média de acertos, recall e f-measure teve o resultado de 92,1% e para precisão o resultado atingido foi de 92,26%, utilizando o SVM. Além disso, o seu tempo médio de execução foi de 5min 59s, superior ao GFB e inferior ao LBP.

Em virtude do que foi apresentado o LPQ usando o SVM mostrou melhores resultados, pois a taxa média de acerto, precisão, recall e f-measure são fundamentais para problemas relacionados a doenças, e o descritor conseguiu atingir média superior, comparado aos outros descritores aplicados neste trabalho. Além disso, segundo o artigo ([NUWER, 1997](#)), são considerados aceitáveis algoritmos com sensibilidade acima de 80% e esse método atingiu cerca de 90% de sensibilidade, mostrando que

o método pode encontrar boa aceitação clínica.

7.1 Trabalhos Futuros

Visando a continuidade deste trabalho, existem alguns caminhos a serem explorados como forma de encontrar melhores resultados. Como foi apresentado, este trabalho utilizou os descritores LBP, LPQ e Banco de Filtros de Gabor, porém, outros descritores podem ser aplicados na tentativa de aumentar a taxa média de acerto, ou diminuir o tempo de execução, tais como variações da do descritor LBP (LIU *et al.*, 2017). Na tarefa de classificação, podemos utilizar algoritmos de Aprendizado Profundo tais como os apresentados no survey recente de Liu *et al.* (LIU *et al.*, 2019). Além disso, a base de imagens poderia ser expandida como forma de aumentar a variação dos dados coletados pelos descritores e classificados pelos algoritmos. Por fim, como este trabalho se aplica em um conjunto de imagens baseadas em exames de EEG, pode-se seguir a metodologia apresentada utilizando exames de outras doenças como, encefalites, tumores cerebrais, hemorragia, edema cerebral, entre outras.

7.2 Contribuições

Neste trabalho foi construída uma base de dados com 200 imagens de recorrência obtidas de séries temporais baseadas em exames EEG para diagnóstico da epilepsia. Como contribuição, a metodologia elaborada também pode ser aplicada em outras doenças ou problema, dos quais também sejam representadas por séries temporais. Além disso, um estudo dos descritores baseados em texturas LBP, LPQ e Banco de Filtros de Gabor combinados com os classificadores SVM e Random Forest, foram utilizados para obter resultados relevantes e ainda não explorados na literatura para o problema de Epilepsia.

Referências

- ALVES; WONDER, S.; LIBRANTZ, A. Reconhecimento de padrões de texturas em imagens digitais usando uma rede neural artificial híbrida. In: . [S.l.: s.n.], 2013. v. 4, p. 2–4.
- AMARAL, B. F. d.; SOUSA, E. P. M. d. Classificação semissupervisionada de séries temporais extraídas de imagens de satélite. 2016.
- ANDRZEJAK, R. et al. Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state. *Physical review. E, Statistical, nonlinear, and soft matter physics*, v. 64, p. 061907, 01 2002.
- Assistência à Saúde de Pacientes com Epilepsia (ASPE). *O que é epilepsia?* 2018. Disponível em: <<http://www.aspebrasil.org/index.php/noticias/74-o-que-e-epilepsia>>. Acesso em: 9 de nov de 2018.
- BRAHNAM, S. et al. Local phase quantization texture descriptor for protein classification. In: *BIOCOMP*. [S.l.: s.n.], 2010.
- CARL; RHODES, M. M. The false nearest neighbors algorithm: An overview. *International Journal of Information Technology*, v. 26, p. 86–96, 1997.
- CASSIO et al. Estudo comparativo entre os algoritmos de mineração de dados random forest e j48 na tomada de decisão. v. 2, 2016.
- CERQUEIRA, A. d. O. J. A. C.; ALVES. Classificação de imagens de alta resolução espacial para mapeamento do tipo de pavimento urbano. *CIII Simpósio Brasileiro de Ciências Geodésicas e Tecnologias da Geoinformação*, 2010. Disponível em: <https://www3.ufpe.br/cgtg/SIMGEOIII/IIISIMGEO_CD/artigos/FotoeSR/SR_e_PDI/A_26.pdf>. Acesso em: 10 de out de 2019.
- Dawood, H.; Dawood, H.; Guo, P. Combining the contrast information with lpq for texture classification. In: IEEE. *2012 6th International Conference on Sciences of Electronics, Technologies of Information and Telecommunications (SETIT)*. [S.l.], 2012. p. 380–385.
- DORA et al. A novel optimal gabor algorithm for face classification. In: *Soft Computing for Problem Solving. Advances in Intelligent Systems and Computing*, vol 817. [s.n.], 2019. p. 58–59. Disponível em: <https://link.springer.com/chapter/10.1007/978-981-13-1595-4_65>. Acesso em: 29 de out de 2018.
- DUARTE, Y. et al. Evaluating lbp and clbp in classifying of mammograms lesions. In: . [S.l.: s.n.], 2014.
- EDERLON; BARBOSA; CRUZ. Representação de séries temporais usando descritores de forma aplicados a recurrence plots. *Repositório da Produção Científica e Intelectual da Unicamp*, dec 2016.

ELISANGELA; SANTOS. Abordagens para busca de séries temporais representadas por imagens de recorrência. *Repositório da Produção Científica e Intelectual da Unicamp*, dec 2019.

FISSEHA et al. Texture analysis and classification in coherent anti-Stokes Raman scattering (CARS) microscopy images for automated detection of skin cancer. *Computerized Medical Imaging and Graphics*, 2015. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0895611115000592>>. Acesso em: 14 de nov de 2018.

FOUNDATION, E. *Epilepsy Foundation*. 2014. Disponível em: <<https://www.epilepsy.com>>. Acesso em: 10 de out de 2018.

GALVAO, F. et al. Papel do EEG em Casos de Suspeita ou Diagnóstico de Epilepsia. *J Epilepsy Clin Neurophysiol*, 2005. Acesso em: 4 de out de 2018.

G.CASTELLANO, L. et al. Texture analysis of medical images. *Clinical Radiology*, 2004. Acesso em: 4 de nov de 2018.

GILSON MEDEIROS, d. O. J. Máquina de vetores suporte: estudo e análise de parâmetros para otimização de resultado. p. 3–6, 2017.

HALL, M. et al. The WEKA data mining software: an update. *SIGKDD Explorations*, v. 11, n. 1, p. 10–18, 2009.

HASSABALLAH, M.; AWAD, A. Detection and description of image features: An introduction. In: _____. [S.l.: s.n.], 2016. v. 630, p. 1–8.

Hospital Israelita Albert Einstein. *Guia de doenças e sintomas*. 2016. Disponível em: <<https://www.einstein.br/guia-doencas-sintomas/info>>. Acesso em: 6 de out de 2018.

KAYA, O. Y. et al. Two novel local binary pattern descriptors for texture analysis. *Applied Soft Computing*, 2015. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1568494615003580>>. Acesso em: 13 de nov de 2018.

Li, W. et al. Designing compact gabor filter banks for efficient texture feature extraction. In: IEEE. *2010 11th International Conference on Control Automation Robotics Vision*. [S.l.], 2010. p. 1193–1197.

LIU, L. et al. From bow to cnn: Two decades of texture representation for texture classification. *International Journal of Computer Vision*, Springer, v. 127, n. 1, p. 74–109, 2019.

LIU, L. et al. Local binary features for texture classification: Taxonomy and experimental study. *Pattern Recognition*, Elsevier, v. 62, p. 135–160, 2017.

Liu, L. et al. Median robust extended local binary pattern for texture classification. *IEEE Transactions on Image Processing*, v. 25, n. 3, p. 1, March 2016.

LUIZ, A. et al. Compound local binary pattern para reconhecimento de expressões faciais. In: . [S.l.: s.n.], 2015.

MARCELO et al. Uma avaliação de descritores de textura baseados em códigos binários locais para classificação de imagens de sensoriamento remoto. p. 552–553, 2011.

MARTINERIE, J. M. Mutual information, strange attractors, and the optimal estimation of dimension. *PHYSICS FACULTY RESEARCH AND SCHOLARSHIP*, 1992.

MARWAN, N. et al. Recurrence plots for the analysis of complex systems. *Physics Reports*, v. 438, n. 5, p. 237 – 329, 2007. ISSN 0370-1573. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0370157306004066>>.

MASOOD et al. Comparative analysis of texture descriptors for classification. 2016. Acesso em: 20 de set de 2018.

MATHWORKS. *Documentação LBP matlab*. Disponível em: <<https://www.mathworks.com/matlabcentral/mlc-downloads/downloads/submissions/36478/versions/1/previews/PaReLab/DbMultiFea/DbFea/FeatureLbp/LPQMatlab/lpq.m/index.html>>. Acesso em: 18-10-2019.

MING, Y.; WANG, G.; FAN, C. Uniform local binary pattern based texture-edge feature for 3d human behavior recognition. *PLOS ONE*, v. 10, p. e0124640, 05 2015.

Minutos Saudável. *Eletroencefalograma (EEG): o que é, tipos e para que serve o exame?* 2017. Disponível em: <<https://minutosaudavel.com.br/eletroencefalograma-eeg-o-que-e-tipos-e-para-que-serve-o-exame-2>>. Acesso em: 20 de set de 2018.

MOHAMED et al. Breast tumor classification in ultrasound images using texture analysis and super-resolution methods. *Engineering Applications of Artificial Intelligence*, 2017. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0952197616302561>>. Acesso em: 20 de nov de 2018.

MOREIRA, S. R. G. Epilepsia: concepção histórica, aspectos conceituais, diagnóstico e tratamento. p. 107–122, 2004.

NUWER, M. Assessment of digital eeg, quantitative eeg, and eeg brain mapping: Report of the american academy of neurology and the american clinical neurophysiology society*. *Neurology*, Wolters Kluwer Health, Inc. on behalf of the American Academy of Neurology, v. 49, n. 1, p. 277–292, 1997. ISSN 0028-3878. Disponível em: <<https://n.neurology.org/content/49/1/277>>.

OJALA, T.; PIETIKÄINEN, M.; HARWOOD, D. A comparative study of texture measures with classification based on featured distributions. *Pattern recognition*, Elsevier, v. 29, n. 1, p. 51–59, 1996.

ORGANIZATION, W. H. *Epilepsia: um imperativo de saúde pública*. 2019. Disponível em: <[Epilepsia:umimperativodesaúde pública](#)>. Acesso em: 11 de nov de 2019.

PEDREGOSA, F. et al. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, v. 12, p. 2825–2830, 2011.

PHAM, T. D. Texture classification and visualization of time series of gait dynamics in patients with neuro-degenerative diseases. *IEEE TRANSACTIONS ON NEURAL SYSTEMS AND REHABILITATION ENGINEERING*, VOL. 26, 2018. Acesso em: 2 de nov de 2018.

PHILOMINA; SIMON, V. U. Review of texture descriptors for texture classification. 2018. Acesso em: 5 de out de 2018.

RAJEANDRA, U. et al. Automated diagnosis of epilepsy using cwt, hos and texture parameters. *International Conference on Pattern Recognition, 22nd, 2014, Stockholm.*, 2013. Acesso em: 14 de out de 2018.

Revista Saúde Abril. *O que é epilepsia e como evitar os ataques.* 2017. Disponível em: <<https://saude.abril.com.br/medicina/o-que-e-epilepsia-e-como-evitar-os-ataques/>>. Acesso em: 14 de nov de 2018.

SHUJUN et al. Applications of support vector machine (svm) learning in cancer genomics. *CANCER GENOMICS & PROTEOMICS*, p. 41–51, dec 2018.

SILVA, I. et al. Uma abordagem para detecção e diagnóstico da doença de alzheimer utilizando extratores de textura de haralick. In: . [S.l.: s.n.], 2018.

SIMON, P.; UMA, V. Review of texture descriptors for texture classification. In: . [S.l.: s.n.], 2018.

SOUZA, V. Alves de; SILVA, D.; BATISTA, G. Extracting texture features for time series classification. In: . [S.l.: s.n.], 2014.

TEIXEIRA, W. A. Imitadores da epilepsia: as crises não-epilépticas fisiológicas. 2017. Acesso em: 10 de out de 2018.

THIELO, M.; REZEND. Análise e classificação de séries temporais não estacionárias utilizando métodos não-lineares. p. 13–98, 2000.

TRAVAINI, J. N. Descritores de textura local para reconhecimento biométrico da Íris humana. *Dissertação (Mestrado) — Universidade de São Paulo, São Carlos*, p. 27–31, 2015.

ULYANOV, D. et al. Texture networks: Feed-forward synthesis of textures and stylized images. In: *ICML*. [S.l.: s.n.], 2016. v. 1, n. 2, p. 4.

VICTOR MARCOS A, R. J. et al. Automated pollen identification using microscopic imaging and texture analysis. *Micron*, 2015. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S096843281400167X>>. Acesso em: 14 de nov de 2018.