



Universidade Federal de Uberlândia

Faculdade de Engenharia Elétrica

Programa de Pós- Graduação em Engenharia Elétrica



**O USO DE MODELOS AUTO REGRESSIVOS PARA A
CLASSIFICAÇÃO DE INDIVÍDUOS ACOMETIDOS PELA DOENÇA
DE PARKINSON**

Taciana Abdala Abrahão

UBERLÂNDIA- MG

2017



Universidade Federal de Uberlândia

Faculdade de Engenharia Elétrica



Programa de Pós- Graduação em Engenharia Elétrica

**O USO DE MODELOS AUTO REGRESSIVOS PARA A
CLASSIFICAÇÃO DE INDIVÍDUOS ACOMETIDOS PELA DOENÇA
DE PARKINSON**

Dissertação apresentada ao Colegiado do Programa de Pós-graduação em Engenharia Elétrica da Universidade Federal de Uberlândia como parte dos requisitos para a obtenção do título de Mestre em Engenharia de Controle e Automação.

Taciana Abdala Abrahão

Orientador: Prof. Dr. Márcio José da Cunha

UBERLÂNDIA- MG

2017

UNIVERSIDADE FEDERAL DE UBERLÂNDIA – UFU

Reitor: Valder Steffen Junior

Pró-Reitor de Graduação: Armindo Quillici Neto

Pró-Reitor de Pós-graduação: Carlos Henrique de Carvalho

Diretor da Faculdade de Engenharia Elétrica: Sérgio Ferreira de Paula Silva

Coordenador do Programa de Pós-Graduação Engenharia Elétrica: José Rubens Macedo
Júnior

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU
com dados informados pelo(a) próprio(a) autor(a).

A159 Abrahão, Taciana Abdala, 1988-

2017 O uso de modelos auto regressivos para a classificação de indivíduos acometidos pela Doença de Parkinson [recurso eletrônico] / Taciana Abdala Abrahão. - 2017.

Orientador: Márcio José da Cunha.
Dissertação (Mestrado) - Universidade Federal de Uberlândia,
Pós-graduação em Engenharia Elétrica.

Modo de acesso: Internet.

Disponível em: <http://doi.org/10.14393/ufu.di.2019.2485>

Inclui bibliografia.

Inclui ilustrações.

1. Engenharia elétrica. I. José da Cunha, Márcio , 1978-,
(Orient.). II. Universidade Federal de Uberlândia. Pós-graduação
em Engenharia Elétrica. III. Título.

CDU: 621.3


Bibliotecários responsáveis pela estrutura de acordo com o AACR2:

Gizele Cristine Nunes do Couto - CRB6/2091

Nelson Marcos Ferreira - CRB6/3074



SERVIÇO PÚBLICO FEDERAL
MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA ELÉTRICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA



Ata da defesa de DISSERTAÇÃO DE MESTRADO junto ao Programa de Pós-graduação em Engenharia Elétrica da Faculdade de Engenharia Elétrica da Universidade Federal de Uberlândia.

Defesa de Dissertação de Mestrado Acadêmico, número 666/2017 PPGEE

Data: 31 de outubro de 2017

Discente: TACIANA ABDALA ABRAHÃO

Número de matrícula: 11512EEL015

Título do Trabalho: O uso de modelos auto regressivos para a classificação de indivíduos acometidos pela doença de Parkinson

Área de concentração: Processamento da Informação

Linha de pesquisa: Redes de Computadores

As 09:00 horas do dia 31 de outubro do ano de 2017 na Sala de Defesas da Faculdade de Engenharia Elétrica, Campus Santa Mônica da Universidade Federal de Uberlândia, reuniu-se a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Engenharia Elétrica, assim composta:

Márcio José da Cunha (orientador)

CPF: 298.522.678-33

Adriano Oliveira Andrade

CPF: 782.832.991-15

Aline Fernanda Bianco

CPF: 295.108.738-10

Iniciando os trabalhos o presidente da mesa Prof. Dr. Márcio José da Cunha apresentou a Comissão Examinadora e a candidata, agradeceu a presença do público, e concedeu a Discente a palavra para a exposição do seu trabalho. A duração da apresentação da Discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir o senhor presidente concedeu a palavra, pela ordem sucessivamente, aos examinadores, que passaram a arguir a candidata. Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu os conceitos finais.

Em face do resultado obtido, a Banca Examinadora considerou a candidata A provada.

Esta defesa de Dissertação de Mestrado Acadêmico é parte dos requisitos necessários à obtenção do título de Mestre. O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

Nada mais havendo a tratar, foram encerrados os trabalhos às 11 horas e 05 minutos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.

Prof. Dr. Márcio José da Cunha
UFU

Prof. Dr. Aline Fernanda Bianco
CEFET

Prof. Dr. Adriano Oliveira Andrade
UFU

Aos meus queridos pais, Romilda Abdala Elias e
Gilberto Reis Abrahão.

Agradecimentos

Primeiramente, agradeço a Deus por estar sempre comigo me fortalecendo durante toda a minha caminhada e por me permitir chegar até aqui;

Ao meu orientador, Prof. Dr. Márcio José da Cunha pela constante dedicação e paciência, fazendo-se sempre presente durante toda a elaboração deste trabalho. Sou grata pelos ensinamentos, incentivos, carinho e orientação. Obrigada por me proporcionar esse período de imensurável crescimento profissional e pessoal;

A todos os queridos mestres, exemplos de profissionalismo e competência, deixo minha gratidão e homenagem;

À Universidade Federal de Minas Gerais pela oportunidade de realização de créditos durante o segundo semestre do meu Mestrado. Agradeço por ter sido acolhida favoravelmente como parte do corpo discente da instituição e por todo o apoio durante esse período.

Ao Prof. Dr. Adriano de Oliveira Andrade que disponibilizou os dados de coleta dos indivíduos tornando possível a realização dessa pesquisa e ao seu aluno de Doutorado, Fábio Henrique Oliveira, pelos materiais cedidos que auxiliaram no desenvolvimento do estudo.

Aos meus pais, que mesmo a alguns quilômetros de distância sempre se fizeram presente compartilhando dos meus ideais e me incentivando a prosseguir na jornada. Pelo amor e carinho incondicional que me deu força para conseguir finalizar mais essa etapa com garra e determinação. Obrigada pela confiança depositada em mim e por compreenderem a minha ausência durante todo esse tempo.

A toda minha família e amigos que compreenderam minhas faltas e me encorajaram com amor incondicional e conversas motivadoras.

A todos que colaboram de forma direta ou indireta na elaboração desse trabalho.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio financeiro.

Resumo

A doença de Parkinson é a segunda doença neurodegenerativa mais comum que afeta até seis milhões de pessoas em todo mundo. Há vários anos o diagnóstico de indivíduos com essa doença tem sido obtido através de escalas e questionários. Esses métodos são caracterizados como mensurações subjetivas pois os resultados dependem da experiência dos profissionais da saúde o que aumenta a probabilidade de erros. A correta avaliação da doença é substancial para se obter informações que contribuam para a decisão do tratamento apropriado para cada sujeito. Nesse estudo foram empregados métodos de análise objetiva com a finalidade de visualizar e diferenciar as características do movimento entre grupos de indivíduos com doença de Parkinson submetidos ao tratamento medicamentoso e de sujeitos neurologicamente saudáveis. Sinais captados de 26 sujeitos por um acelerômetro foram obtidos do banco de dados de um estudo (MACHADO, 2016) [4] e utilizados como medidas para o desenvolvimento desse trabalho. Dentre o total de indivíduos, 10 deles são saudáveis e 16 são portadores da doença de Parkinson sendo tratados Levedopa. Desse estudo (MACHADO, 2016) [4], utilizou-se apenas os sinais resultantes da tarefa estática, na qual o sujeito permanecia com o cotovelo em extensão sem movimentos voluntários e do acelerômetro pertencente ao dispositivo localizado na mão. A partir desses dados, a presente pesquisa criou um sistema para discriminar sujeitos acometidos pela Doença de Parkinson de indivíduos saudáveis usando os parâmetros de um modelo Auto Regressivo. Foram modeladas equações matemáticas com 2 a 10 parâmetros a fim de se encontrar qual delas melhor classifica os sujeitos nos grupos correspondentes. Para se obter esse resultado foi utilizado um método de reconhecimento de padrões com índices de desempenho. O método proposto nesse estudo foi validado, portanto é capaz de discriminar os dois grupos de indivíduos com mais eficácia em uma determinada quantidade de parâmetros.

Palavras chaves: Doença de Parkinson, Identificação de Sistemas, Modelo Auto Regressivo, KNN.

Abstract

The Parkinson's disease is the second most common neurodegenerative disease affecting up to six million people in the world. For several years the diagnosis of individuals with this disease has been obtained through scales and questionnaires. These methods are characterized as subjective measurements because the results depend on the experience of health professionals which increases the probability of errors. The correct evaluation of the disease is substantial to obtain information that contributes to the decision of the appropriate treatment for each subject. In this study, objective analysis methods were used to visualize and differentiate the characteristics of the movement between groups of individuals with Parkinson's disease submitted to drug treatment and neurologically healthy subjects. Signals collected from 26 subjects by an accelerometer were obtained from a study database (MACHADO, 2016) [4] and used as measures for the development of this work. Among the total of individuals, 10 of them are healthy and 16 are carriers of Parkinson's disease being treated with Levedopa. From this study (MACHADO, 2016) [4], we used only the signals resulting from the static task, in which the subject remained with the elbow in extension without voluntary movements and from the accelerometer belonging to the device located in the hand. From these data, the present research created a system to discriminate individuals affected by Parkinson's disease from healthy individuals using the parameters of an Auto Regressive model. Mathematical equations were modeled from 2 to 10 parameters in order to find which one best classifies the subjects in the corresponding groups. To obtain this result we used a pattern recognition method with performance indexes. The method proposed in this study was validated, therefore it is able to discriminate the two groups of individuals most effectively with a certain amount of parameters.

Keywords: Parkinson's Disease, System Identification, Auto Regressive Model, KNN.

Sumário

1. INTRODUÇÃO E JUSTIFICATIVA	12
1.1. Objetivos do Trabalho	14
1.2. Organização da Dissertação.....	15
2. FUNDAMENTAÇÃO TEÓRICA	17
2.1. Doença de Parkinson	17
2.2. Diagnóstico da Doença de Parkinson	18
2.3. Sistemas para Capturar Movimentos Humanos	21
2.3.1. Giroscópio	22
2.3.2. Magnetômetro.....	22
2.3.3. Acelerômetro	22
2.3.4. Sensor Eletromiográfico (EMG)	23
2.3.5. Montagem dos Sensores	23
2.4. Identificação de Sistemas	24
2.4.1. Identificação Paramétrica	31
2.5. Reconhecimento de Padrões.....	32
2.5.1. Análise Estatística	35
2.5.2. Algoritmo KNN.....	36
2.5.3. Análise de Classificação.....	36
3. ESTADO DA ARTE	38
3.1. Métodos para Avaliação Objetiva do Movimento Humano.....	38
4. MÉTODOS E MATERIAIS	41
4.1. Dados Utilizados	41
4.2. Obtenção dos Modelos Matemáticos.....	43
4.3. Classificação KNN e Validação Cruzada.....	45
4.4. Índices de Desempenho gerados pelo Classificador KNN.....	46
5. DISCUSSÕES E RESULTADOS	49
5.1. Visualização dos Resultados da Modelagem Matemática.....	51
5.2. Resultados da Classificação de Padrões	51
6. CONCLUSÕES	58
REFERÊNCIAS BIBLIOGRÁFICAS	60

Lista de Figuras

Figura 1. Fluxograma das principais etapas de um processo de identificação de sistemas. Fonte: Gonçalves (2014) [27].....	25
Figura 2. Diagrama de Ajuste do Modelo de Identificação. Fonte: Adaptado de Coelho Antônio e Coelho Leandro (2015) [25]	30
Figura 3. Procedimento do estimador dos Mínimos Quadrados Recursivos. Fonte: Adaptado de COELHO Antônio e COELHO Leandro (2015) [25]	32
Figura 4. Fluxograma do modelo básico para classificação automática de padrões. Fonte: Adaptado de Andrade (2000) [29].....	34
Figura 5. Luva com os dois conjuntos de sensores inerciais utilizada na aquisição de dados sendo que os dados considerados nesse trabalho foram coletados a partir do acelerômetro presente no conjunto 1. Fonte: Machado (2016) [4].	42
Figura 6. Tarefa realizada pelo paciente com cotovelo em extensão, sem realização de movimento voluntário. Fonte: Machado (2016) [4].	42
Figura 7. Simulação do sinal obtido pelo acelerômetro do sensor 1 usados no projeto com os dados do paciente 16.....	43
Figura 8. Gráfico de Desempenho do Método de Classificação KNN no ClassificationLearner a partir da análise dos dados estudados utilizando o modelo AR com 2 parâmetros.....	45
Figura 9. Sinal Simulado pelo modelo AR de Segunda Ordem X Sinal Real para dados do sujeito 16.	49
Figura 10. Gráfico da Média do Erro Quadrático Médio para cada modelo matemático.	50

Lista de Tabelas

Tabela 1. Parâmetros obtidos para o sujeito 16 a partir da modelagem AR.....	44
Tabela 2. Valor médio dos indicadores de desempenho do classificador KNN para cada modelo Auto Regressivo.	51
Tabela 3. Valor do desvio padrão de cada um dos índices de desempenho para cada modelo AR.....	52
Tabela 4. Melhores modelos matemáticos a partir da avaliação do índices: verdadeiro positivo e verdadeiro negativo.....	53
Tabela 5. Porcentagem das medidas verdadeiro positivo e verdadeiro negativo e a média dos dois índices.	53
Tabela 6. Medidas de desempenho calculadas a partir dos resultados do classificador KNN para análise do melhor modelo AR.	54
Tabela 7. Valores do desvio padrão para cada uma das médias de desempenho calculadas. ..	54
Tabela 8. Melhores e Piores medidas de Sensibilidade e Especificidade para os modelos observados.	55
Tabela 9. Conclusão da análise dos melhores modelos considerando a precisão e a acurácia.	55

Lista de Siglas

A	Acurácia
ADL	Activities of Daily Living (Atividades da Vida Diária)
AR	Auto Regressive (Auto Regressivo)
ARMA	Auto Regressive Moving Average (Auto Regressivo com Média Móvel)
ARMAX	Auto Regressive Moving Average with Exogenous Inputs (Auto Regressivo com Média Móvel e Entradas Externas)
ARX	Auto Regressive with Exogenous Inputs (Auto Regressivo com Entradas Externas)
DBS	Deep Brain Stimulation (Estimulação Profunda do Cérebro)
DP	Doença de Parkinson
E	Especificidade
E/S	Entrada/Saída
FN	Falso Negativo
FP	Falso Positivo
HR-QoL	Health-Related Quality of Life (Qualidade de Vida relacionada à saúde)
HY	Hoehn and Yahr
ICIDH	International Classification of Impairments, Disabilities, and Handicaps
KNN	K-Nearest Neighbors (K- Vizinhos Mais Próximos)
LMS	Least Mean Square (Mínimos Quadrados)
NaN	Not a Number
OMS	Organização Mundial da Saúde
P	Precisão
PDQ-39	Parkinson Disease Questionnaire (Questionário da Doença de Parkinson)

PDQL	Parkinson Disease Quality of Life (Qualidade de Vida Na Doença de Parkinson)
REM	Rapid Eye Movement (Movimento Rápido do Olho)
RLS	Recursive Least Square (Mínimos Quadrados Recursivos)
RP	Reconhecimento de Padrões
S	Sensibilidade
SDP	Sujeito com Doença de Parkinson tratado com Levedopa
SEPC	Sujeito com Doença de Parkinson tratado com Estimulação Profunda do Cérebro
SNC	Sistema Nervoso Central
SNpc	Substantia Nigra Pars Compacta (Par Compacto da Substância Negra)
SS	Sujeito Saudável
SVMs	Support Vector Machine (Máquinas de Vetor de Suporte)
UPDRS	Unified Parkinson's Disease Rating Scale (Escala Unificada de Classificação da Doença de Parkinson)
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo

Capítulo 1

INTRODUÇÃO E JUSTIFICATIVA

A doença de Parkinson (DP) é a segunda doença neurodegenerativa mais comum que afeta cerca de 1-2% da população acima de 60 anos e até seis milhões de pessoas no mundo todo (SOUZA, 2011) [1]. É uma síndrome clínica degenerativa e progressiva caracterizada pela deficiência de dopamina no sistema nervoso central (SNC) na região dos gânglios da base, a qual leva a uma desordem de movimento caracterizada pelos sinais e sintomas motores parkinsonianos, além de alterações emocionais e déficits cognitivos. Estes sintomas clássicos incluem a bradicinesia, a rigidez muscular, o tremor de repouso e o comprometimento da postura e da marcha. Os graus distintos da doença manifestam os sintomas com predominâncias diferentes que estão relacionados com padrões de início e velocidade de progressão, além dos padrões genéticos (SOUZA, 2011) [1].

O tremor parkinsoniano é descrito como tremor de repouso, o qual manifesta-se quando a parte do corpo afetada não está em atividade voluntária. Com isso, esse tremor pode ser eliminado no início de uma ação e desaparecer no sono e completo relaxamento, enquanto tende a se acentuar em situações de estresse, durante a marcha e com distrações mentais. Os membros superiores é a parte do corpo com acometimento mais frequente seguida dos membros inferiores e mento (BORGES e FERRAZ, 2006) [2].

A DP possui um caráter de progressão lenta e à medida que a doença progride, os sintomas cardinais motores, bem como o declínio cognitivo, os problemas neuropsicológicos, a falha autonômica e as complicações relacionadas ao tratamento associado à medicação reduzem significativamente as atividades da vida diária (*ADL- Activities of Daily Living*) do paciente e a qualidade de vida relacionada à saúde (*HR-QoL- Health-Related Quality of Life*). O conjunto de características não-motoras da Doença de Parkinson inclui sintomas neuropsiquiátricos, distúrbios do sono, queixas sensoriais. Estes sintomas não motores geralmente estão correlacionados com o avanço da idade e com a gravidade da doença, enquanto outros sintomas não motores como disfunção olfativa, distúrbio do comportamento do sono, depressão e

sintomas gastrointestinais podem ocorrer no início da doença e se agravam em paralelo com os sintomas motores (CHEN e TSAI, 2010) [3].

Dentre os vários medicamentos usados para tratar a DP, o fármaco levodopa é amplamente utilizado desde os anos 70 (MACHADO, 2016) [4]. Existem outras opções para o tratamento dessa doença, incluindo procedimentos cirúrgicos ablativos assim como a Estimulação Profunda do Cérebro (*DBS- Deep Brain Stimulation*) nas regiões do tálamo, globo pálido ou no núcleo subtalâmico (MACHADO, 2016) [4].

A correta avaliação do paciente é substancial e deve ser conduzida sistematicamente tanto para estudos epidemiológicos, farmacológicos e clínicos, quanto para se obter informações que contribuam para o tratamento apropriado de cada paciente (GOULART e PEREIRA, 2005) [5].

Apesar dos avanços obtidos em neuroimagem e genética, o diagnóstico da DP ainda é essencialmente clínico e consiste, inclusive, na comparação visual. Essa avaliação subjetiva da doença dificulta o diagnóstico e aumenta a probabilidade de erros (RIZZO et al 2016) [6].

Uma das formas de avaliar se o indivíduo possui a DP e qual o seu estágio é por meio das escalas de severidade e questionários. Dentre as diversas escalas existentes, destaca-se a Escala Unificada de Classificação da Doença de Parkinson, do inglês *Unified Parkinson's Disease Rating Scale (UPDRS)* (The Unified Parkinson's Disease Rating Scale (UPDRS): Status and recommendations, 2003) [7]. Essa escala avalia os sinais, sintomas e determinadas atividades dos pacientes por meio do auto relato e da observação clínica (GOULART e PEREIRA, 2005) [5]. Apesar dos pontos fortes de avaliação da UPDRS, como cobertura quase abrangente de sintomas motores e suas propriedades clinimétricas, essa escala apresenta desvantagens como instruções inadequadas para avaliadores, algumas falhas métricas e a ausência de perguntas de triagem em vários aspectos não-motores importantes da DP (The Unified Parkinson's Disease Rating Scale (UPDRS): Status and recommendations, 2003) [7].

Além disso, esta análise impede a extração de informações críticas da atividade do tremor, como frequência, amplitude e velocidade (ANDRADE et al., 2013) [8]. Com isso, conclui-se que existe a necessidade de um método objetivo e eficaz para o diagnóstico da doença que não seja susceptível aos erros humanos.

Com o intuito de fornecer diagnósticos padronizados e objetivos a partir da correta avaliação dos indivíduos com a Doença de Parkinson e dos neurologicamente saudáveis e acompanhamento adequado dessa doença, estudos recentes apresentam métodos que fazem uso de sensores inerciais para quantificar e diagnosticar o tremor (MACHADO, 2016; LEYMOYNE et al., 2009; DAI et al., 2015; NIAZMAND et al., 2011; BASU et al., 2013). Pesquisas com acelerômetro estão sendo testadas e avaliadas para determinar o estado geral, a

eficácia da terapia medicamentosa e a melhoria da doença de Parkinson. Algumas pesquisas, por exemplo, fizeram uso desse sensor inercial para avaliar a severidade da bradicinesia e os sintomas motores dessa característica em pacientes com DP (DAI et al. 2015; NIAZMAND et al., 2011).

O estudo de revisão Machado (2016) [4], com o objetivo de melhor entender a DP e os resultados de seus tratamentos, utilizou sensores inerciais e sensores eletromiográficos para mensurar o movimento e a atividade muscular resultante de tarefas entre grupos de pacientes com a DP submetidos ao tratamento medicamentoso, ao tratamento com Estimulação Profunda do Cérebro e um grupo controle com sujeitos saudáveis.

Após realizar uma revisão literária, descrita na próxima seção, e analisar os avanços com sensores inerciais no diagnóstico e acompanhamento da DP, essa pesquisa propõe o uso de um método de análise de série temporal dos sinais captados por um acelerômetro de indivíduos saudáveis e com tremor parkinsoniano. Os dados utilizados para essa análise vêm do acelerômetro utilizado no projeto de Machado (2016) [4], o qual possui um sistema de sensores inerciais composto por uma luva para a realização da coleta. Para analisar as características desses dados foram utilizados parâmetros de um modelo Auto Regressivo (*AR- Auto Regressive*), os quais possuem informações quantitativas das mudanças nos sinais motores da mão dos pacientes. Por fim, com o objetivo de determinar qual a ordem do modelo que melhor separa indivíduos saudáveis de indivíduos com a Doença de Parkinson foi utilizado o classificador K- Vizinhos Mais Próximos (*K – NearestNeighbors*) (MATHWORKS. Classification KNN class) [13].

1.1. Objetivos do Trabalho

Conforme apresentado, um dos grandes problemas do diagnóstico da DP por questionários e escalas é a subjetividade do método que depende da experiência do profissional da saúde. Nesse contexto, o presente trabalho tem como principais objetivos:

- Implementar um algoritmo no software MATLAB para identificação de sistemas utilizando um modelo matemático Auto Regressivo;
- A partir do algoritmo, gerar modelos com 2 a 10 parâmetros para os sinais de cada sujeito analisado;

- Analisar pela ferramenta *ClassificationLearner* do software MATLAB qual método de análise estatística possui melhor acurácia na classificação dos grupos: sujeitos acometidos pela Doença de Parkinson e sujeitos neurologicamente saudáveis;
- Implementar no MATLAB um algoritmo do melhor método de análise estatística encontrado na análise realizada com auxílio da ferramenta;
- Extrair características de desempenho de cada modelo matemático;
- Avaliar qual a quantidade de parâmetros dos modelos matemáticos que melhor representa a diferenciação dos grupos;
- Validar o método proposto;
- Sugerir trabalhos futuros que possam ser desenvolvidos a partir desse estudo.

1.2. Organização da Dissertação

Os capítulos desse trabalho foram organizados conforme uma sequência detalhada de cada etapa realizada para atingir os objetivos citados acima. Estruturalmente, a dissertação foi dividida em seis capítulos:

No capítulo 1 é apresentada uma breve introdução acompanhada da motivação que levou a realização do estudo, os objetivos e a organização da dissertação.

No capítulo 2 é apresentada a fundamentação teórica a qual descreve a revisão da literatura sobre a doença de Parkinson, formas utilizadas para diagnóstico dessa doença, sistemas atualmente implantados para capturar movimentos humanos citando os sensores inerciais e sensores eletromiográficos além das formas usadas para montagem dos mesmos. Ainda nesse capítulo são apresentadas as descrições das estratégias utilizadas nesse estudo para classificar os indivíduos a partir dos dados coletados. Nessas estratégias são descritas informações básicas a respeito da identificação de sistemas, estimação dos parâmetros do modelo, classificador de padrões, análise estatística dos dados e detalhes sobre o classificador KNN utilizado nesse trabalho.

No capítulo 3 é feita uma apresentação do estado da arte referente às pesquisas relacionadas às técnicas objetivas para a análise e processamento dos sinais de tremor.

Os métodos e materiais utilizados no desenvolvimento do projeto são apresentados no capítulo 4. Primeiramente, são descritas algumas partes do estudo responsável pela coleta do sinal, apresentando as características dos grupos dos indivíduos envolvidos no trabalho e os

instrumentos para a captação e tratamento do sinal. Depois, são descritas as etapas do processo para o modelo escolhido na modelagem do sinal, na classificação dos parâmetros e validação do método, além da descrição dos índices de desempenho para analisar qual o modelo melhor diferencia os indivíduos com Doença de Parkinson dos indivíduos neurologicamente saudáveis.

No capítulo 5 são apresentados os resultados obtidos neste trabalho e a discussão sobre a validação do método utilizado e do desempenho dos melhores e piores modelos matemáticos.

No capítulo 6, finalmente, são expostas as conclusões finais relevantes dessa dissertação, assim como as sugestões para trabalhos futuros que podem ser realizados a partir das análises obtidas nesse projeto.

Capítulo 2

FUNDAMENTAÇÃO TEÓRICA

Neste capítulo é feita uma fundamentação teórica acerca da Doença de Parkinson e dos métodos de escalas e de questionários usados para o diagnóstico da mesma. Além disso, ferramentas utilizadas como alternativas objetivas para captar, analisar e avaliar os sinais de tremor são apresentadas.

2.1. Doença de Parkinson

Em 1817 um médico inglês conhecido como James Parkinson descobriu a doença e publicou um estudo chamado de “Ensaio da Paralisia de Agitação”, onde descreveu de forma precisa a doença e seus sintomas. Apesar desse estudo, foi somente 6 décadas depois que o neurologista francês Jean Martin Charcot reconheceu a importância do trabalho e além de denominar a doença com o nome de Parkinson, descreveu seus aspectos clínicos (WERNECK, 2010) [14].

A característica patológica crucial da doença de Parkinson é a perda de neurônios dopaminérgicos dentro do par compacto da substância negra (SNpc) que causa os sintomas motores parkinsoniano como tremor, bradicinesia, rigidez e instabilidade postural. O tremor é tipicamente o primeiro sintoma motor em pacientes com a doença de Parkinson e se apresenta principalmente nas mãos, pés e cabeça (MACHADO, 2016; KALIA e LANG, 2015).

A perda neuronal dopaminérgica moderada a severa na SNpc, conforme resultados de estudos de correlação clínico-patológica, é provavelmente a causa de características motoras, bradicinesia e rigidez em particular, na doença de Parkinson avançada. Pesquisas atuais confirmam que a perda moderada de neurônios nigrais também está presente em estágios iniciais da doença, mas também fornece evidências de uma população de neurônios dopaminérgicos potencialmente recuperáveis. O principal suporte para a administração da

doença de Parkinson é tratar os sintomas com drogas que aumentam as concentrações de dopamina ou estimulam diretamente receptores de dopamina (KALIA e LANG, 2015) [15].

A doença de Parkinson é considerada o segundo transtorno neurodegenerativo mais comum apresentando maior predomínio nos países da Europa, América do Norte e América do Sul quando comparado com os da África, Ásia e Arábia.

A idade é o maior fator de risco para o desenvolvimento dessa doença sendo que a prevalência e a incidência aumentam quase que exponencialmente com a idade e atinge o pico após 80 os anos. Esta tendência tem implicações importantes para a saúde pública visto que com o envelhecimento da população e o aumento da expectativa de vida em todo o mundo, espera-se que o número de pessoas com doença de Parkinson aumente mais de 50% até 2030. Além disso, o sexo masculino é mais predisposto a desenvolver esta patologia que o sexo feminino, numa proporção de 3 homens para 2 mulheres. Também há a contribuição da genética que é sugerida pelo aumento do risco de doença associado a história familiar de doença de Parkinson ou tremor (KALIA e LANG, 2015) [15].

Outro fator de risco para a ocorrência da DP são as exposições ambientais. Um estudo realizado analisou 30 potenciais fatores de riscos diferentes e identificaram 11 fatores ambientais que alteram significativamente os riscos da DP. Os fatores que aumentam o risco são exposição a pesticidas, lesões prévias na cabeça, vida rural, uso de fármacos Beta-bloqueadores, ocupação agrícola e consumo de água potável (KALIA e LANG, 2015) [15].

A DP inclui características não motoras, tais como disfunção olfativa, comprometimento cognitivo, sintomas psiquiátricos, distúrbios do sono, disfunção autonômica, dor e fadiga. Esses sintomas são comuns no início da doença e estão associados à redução da qualidade de vida relacionada à saúde. As características não-motoras também estão frequentemente presentes na doença de Parkinson antes do início dos sintomas motores clássicos. Esta fase premotora ou prodrômica da doença pode ser caracterizada por insuficiência de olfação, constipação, depressão, sonolência diurna excessiva e movimento rápido do olho (*REM- Rapid Eye Movement*) distúrbio de comportamento do sono.

2.2. Diagnósticos da Doença de Parkinson

A adequada avaliação do paciente e correto diagnóstico da doença de Parkinson é fundamental para a obtenção de informações que contribuam para a tomada de decisão clínica. Atualmente, o diagnóstico é primordialmente clínico, baseado na história médica e no exame

físico o que torna a avaliação e classificação do indivíduo susceptível a erros (RIZZO et al 2016) [6].

Em 1980, a Organização Mundial da Saúde (OMS) publicou um documento definindo as consequências de doenças ou lesões, intitulado *International Classification of Impairments, Disabilities, and Handicaps* (ICIDH) o qual enfatizava condições baseadas em problemas físicos e motores. A estrutura proposta pela ICIDH apresentava uma relação linear e causal entre deficiência, incapacidade e limitação. Após ser criticada pela sequência fixa de eventos gerada pela progressão linear, essa classificação foi revisada e publicada em 1999 como ICIDH-2. Essa última usa o termo funcionalidade para substituir os da versão anterior com três dimensões: estrutura que identifica alterações em partes anatômicas do corpo, das funções fisiológicas ou psicológicas; atividades que aponta dificuldades no desempenho de tarefas cotidianas e participação que engloba as limitações dos indivíduos no ambiente sociocultural. Com essas dimensões a relação se torna dinâmica, o que significa que a intervenção de um elemento possui potencial para alterar os demais refletindo uma interação em diversos contextos para definir as consequências das condições de saúde (GOULART e PEREIRA, 2005) [5].

Várias escalas são utilizadas para avaliar indivíduos com DP que analisam desde a condição clínica geral, incapacidades, função motora e mental até a qualidade de vida dos pacientes. Dentre elas está a UPDRS, citada na introdução, que é composta por questões que são divididas em quatro partes: atividade mental, comportamento e humor; atividades de vida diária; exploração motora e complicações da terapia medicamentosa. A pontuação dessas questões varia em cada item de 0 a 4, sendo que o valor máximo indica maior comprometimento pela doença e o mínimo, normalidade (GOULART e PEREIRA, 2005) [5]. Essa escala é amplamente utilizada para monitorar a progressão da doença e a eficácia do tratamento medicamentoso devido à sua confiabilidade e validade (The Unified Parkinson's Disease Rating Scale (UPDRS): Status and recommendations, 2003) [7].

Outros questionários e escalas também são utilizados apesar de não serem avaliados (JANKOVIC, 2008) [16]. A Escala de *Hoehn and Yahr* (HY- *Degree of Disability Scale*) indica o estado geral do paciente de uma forma rápida e prática. Compreende 5 estágios de classificação para avaliar a severidade da doença de Parkinson e faz uso de medidas de instabilidade postural, rigidez, tremor e bradicinesia para classificar o indivíduo quanto ao nível de incapacidade. As classificações I, II e III incluem incapacidade leve a moderada, enquanto IV e V apresentam incapacidade mais grave. Recentemente uma versão modificada da HY foi desenvolvida inserindo dois estágios intermediários para avaliar a doença. A forma de avaliação da instabilidade postural é através de um empurrão brusco no paciente para trás a partir dos

ombros. Se o paciente recupera o equilíbrio dando três passos para trás, então ele possui resposta normal, enquanto o paciente com instabilidade pode cair caso não seja amparado pelo examinador. Essa ferramenta inclui exames que analisam a gravidade dos tremores de repouso, postural e cinético. Para a realização dos exames os indivíduos executam tarefas como extensão dos braços, ingestão de líquidos utilizando colheres e copos, desenhos de espirais e movimentos de tocar o nariz com o dedo (GOULART e PEREIRA, 2005; ALMEIDA, 2011).

O exame clínico de Bain é constituído por vários exames que analisam componentes do tremor (tremor de repouso, tremor cinético e tremor intencional). Esses componentes são analisados da seguinte forma: 1- o componente de repouso do tremor da cabeça é avaliado com o paciente deitado em um sofá, com a cabeça apoiada em almofadas enquanto o componente postural é coletado com o paciente sentado sem apoio na cabeça e olhando para frente; 2- o componente postural do tremor dos membros inferiores é analisado com o paciente sentado e com a perna estendida e o de repouso é analisado com os pés do paciente posicionados no chão; 3- para os membros superiores a avaliação é feita com o paciente sentado sendo o componente de repouso do tremor analisado com os braços relaxados e totalmente apoiados no colo do paciente enquanto, o componente postural é analisado com os braços esticados, com a mão pronadas e dedos separados; 4- o componente cinético é medido durante a fase transitória do teste dedo-nariz e componente intencional é medido enquanto o dedo indicador do sujeito se aproxima do alvo posicionado no limite do alcance. Para avaliar o tremor vocal, é analisada a fala de cada paciente e o som do canto, segurando uma nota musical com a voz. As pontuações variam de 0 a 10 para cada tarefa sendo de 0 a 3- leve, de 4 a 6-moderado, de 7 a 9- severo e 10 extremamente grave (ALMEIDA, 2011) [17].

Além das escalas, questionários também são usados na avaliação da DP. O Questionário de Doença de Parkinson (*PDQ-39- Parkinson Disease Questionnaire*) é auto administrável e aborda aspectos pessoais através de entrevistas com indivíduos portadores de DP com objetivo de avaliar a qualidade de vida. São 39 itens divididos em 8 categorias: mobilidade, atividades da vida diária, bem-estar emocional, estigma (avalia várias dificuldades sociais em torno da doença), apoio social (avalia o apoio recebido nas relações sociais), cognição, comunicação e desconforto corporal. A pontuação varia de 0 a 100 sendo que uma baixa pontuação indica melhor estado de saúde (GOULART e PEREIRA, 2005) [5].

Já o Questionário de Qualidade de Vida na Doença de Parkinson (*PDQL- Parkinson Disease Quality of Life*) foi criado baseado em outros questionários de qualidade de vida e em várias entrevistas realizadas por neurologistas com pacientes portadores da DP. O desenvolvimento desse questionário objetivou: ser relativamente simples e curto, ser válido e

suscetível de análises estatísticas, medir a saúde física e emocionam e refletir áreas de funções que são importantes para os indivíduos diagnosticados com DP. O PDQL também é auto administrável e constituído por 37 questões, subdivididos em 4 categorias: sintomas parkinsonianos e sistêmicos, função emocional e social. Sua pontuação varia de 1 a 5 para cada item, sendo a pontuação máxima uma melhor percepção do paciente em relação a sua qualidade de vida (GOULART e PEREIRA, 2005) [5].

Os questionários e escalas subjetivas baseiam-se também na comparação visual dos pacientes o que gera diferentes diagnósticos pela subjetividade do avaliador. Em alguns casos, a diferenciação entre o tremor fisiológico e patológico não pode ser clinicamente analisada.

Segundo Machado (2016) [4], a revisão realizado por Rizzo et al (2016) [6] conclui que a validade dos diagnósticos clínicos da DP não é suficiente e que a exatidão dessas análises não apresentou nenhuma melhora considerável nos últimos 25 anos. O estudo ressalta que outros métodos são necessários para aumentar a acurácia no diagnóstico da DP.

2.3. Sistemas para Capturar Movimentos Humanos

Dispositivos que capturam com precisão o movimento humano são componentes chaves dos sistemas de reabilitação física e de detecção de anormalidades. Estes dispositivos permitem o registro dos movimentos dos pacientes, possibilitando aos profissionais da saúde analisá-los remotamente a partir de resultados quantitativos do movimento. Dentre as diferentes tecnologias utilizadas nos sistemas de captura de movimento, encontram-se os sensores inerciais e sensores eletromiográficos (JORGE, 2013) [18].

Tais técnicas podem ser usadas para verificar o tremor de forma eletrônica eliminando a subjetividade e a limitação da análise e do diagnóstico dos métodos baseados em escalas (ALMEIDA, 2011) [17].

Os sensores inerciais são capazes de rastrear movimentos baseados nas leis de Newton do movimento. Dentre esses sensores encontra-se os acelerômetros, os giroscópios e os magnetômetros, que fornecem uma estimativa precisa da orientação em relação a uma estrutura fixa de referência (JORGE, 2013) [18]. Os dados captados podem ser transmitidos para uma base de trabalho através uma rede sem fio para visualização.

A tecnologia sem fio, ao longo das últimas décadas tem sido desenvolvida para monitorar variáveis fisiológicas e padrões do movimento em diversas aplicações de problemas clínicos, inclusive na monitoração de doenças neurológicas (JORGE, 2013) [18].

2.3.1. Giroscópio

Os giroscópios são dispositivos que medem a velocidade angular e podem, assim como os acelerômetros, quantificar os distúrbios do movimento (MACHADO, 2016) [4]. A unidade de medida mais utilizada é graus por segundo ($^{\circ}/s$).

O princípio de funcionamento desses sensores depende do tipo utilizado. O giroscópio que faz uso do método eletromecânico massa/mola funciona com base no princípio de detecção da aceleração de Coriolis, no qual age sobre uma determinada massa de prova de vibração proporcional a taxa de rotação ao longo de um eixo ortogonal ao eixo vibratório. Se a amplitude da velocidade da massa de prova for conhecida, é possível calcular a velocidade de rotação a partir da medida de aceleração de Coriolis (RABELO, 2016) [19].

2.3.2. Magnetômetro

Os magnetômetros são sensores magnéticos projetados para verificar a direção, sentido e intensidade dos campos magnéticos, cuja unidade de medida geralmente usada é Gauss.

Existem os magnetômetros baseados no sensor magnético de efeito Hall, o qual transforma informações do campo magnético em tensão elétrica e os baseados na força de Lorentz os quais medem os deslocamentos mecânicos através de métodos piezoresistivos ou transdutores eletrostáticos (RABELO, 2016) [19].

2.3.3. Acelerômetro

A acelerometria mede a aceleração linear com relação a um referencial, cuja unidade de medida é em unidades de comprimento por tempo ao quadrado (m/s^2) ou em unidades de gravidade (g). Constitui-se em um dispositivo eletromecânico, baseado no efeito piezoelétrico ou na variação da capacitância que, quando fixado em alguma parte do corpo, é capaz de medir as forças de aceleração ou movimentação causada pelo tremor da área analisada. Essa avaliação fornece uma sequência de números que representam o valor instantâneo da aceleração em função do tempo, cujos dados são armazenados para uma possível investigação computacional. (ALMEIDA, 2011; RABELO, 2016).

Na literatura, esses sensores inerciais já foram aplicados para monitorizar o nível de atividade física humana, para avaliar tremores fisiológicos, na avaliação postural, na identificação e classificação de movimentos, na detecção de queda em idosos, e para medir a

onda de deformação que se propaga ao longo do sistema esquelético quando o pé se choca com o chão durante a locomoção (JORGE, 2013) [18].

É possível fazer uso do acelerômetro tanto em estudos que envolvem movimentos normais quanto em estudos com movimento patológico devido a sua capacidade de medir a intensidade do movimento de um corpo ao longo dos três planos anatômicos. Atualmente, os seus custos e dimensões reduzidas bem como os baixos consumos energéticos permitem a sua utilização fora do ambiente laboratorial (JORGE, 2013) [18].

Atualmente é considerado o método mais difundido para avaliação eletrônica do tremor com custos e dimensões reduzidas o que possibilita a execução dos movimentos sem restrição. Outras vantagens sobre os outros métodos é que os resultados dos acelerômetros estão disponíveis logo após a coleta, o que elimina a necessidade de métodos complexos de processamento, além de responder tanto à frequência quanto a intensidade do movimento. Devido às características citadas, os dados captados por esse sensor inercial no estudo de MACHADO (2016) [4] foram os escolhidos para a validação do método utilizado nesse trabalho.

2.3.4. Sensor Eletromiográfico (EMG)

O sensor eletromiográfico é capaz de medir o sinal EMG observado na superfície da pele sendo esse sinal, o somatório algébrico de todos os potenciais de ação gerados em certa área, provenientes das fibras musculares quando excitadas. Ele pode ser afetado por propriedades musculares, anatômicas e fisiológicas, além do controle do sistema nervoso periférico e da instrumentação utilizada para gerar o sinal (RABELO, 2016) [19].

Os sinais eletromiográficos são coletados por terminais que conectam o sistema eletrônico ao músculo, denominados eletrodos (RABELO, 2016) [19].

2.3.5. Montagem dos sensores

A montagem dos sensores para a captação do sinal é descrito de diversas formas nas revisões literárias do estado da arte. Alguns estudos fazem uso dos sensores fixados diretamente na pele do indivíduo (BASU et al. 2013; PATEL et al., 2009; SHAH et al., 2013; BISWAS et al., 2016; SALARIAN et al., 2007) enquanto outros apresentam sistemas que os utilizam fixados em luvas, conhecidos como sistemas vestíveis (MACHADO, 2016; DAI et al., 2015; NIAZMAND et al., 2011; DAI e D'Angelo, 2013).

Machado (2016) [4] explica que a utilização de luvas para fixar os sensores inerciais oferece um procedimento mais confortável para o voluntário da pesquisa além de facilitar a colocação e precisão do alvo nos vários voluntários.

2.4. Identificação de Sistemas

O termo sistemas pode ser definido de diversas maneiras dependendo da aplicação. Em controle de processos, esta palavra corresponde a um objeto ou conjunto de objetos que executa determinado objetivo e cujas propriedades pretende-se estudar (COELHO Antônio e COELHO Leandro, 2015) [25].

A Identificação de sistemas é um procedimento que propõe a obtenção de um modelo matemático que represente a dinâmica do sistema a ser identificado para utilização particular (detecção de falhas, otimização, controle, entre outros) (CUNHA, 2011) [26].

Para fins de controle de processos, o objetivo não é encontrar um modelo matemático exato e sim um modelo adequado para uma determinada aplicação. Esse modelo responde sobre o sistema sem a realização de experimentos sendo muito útil quando este é complexo e se torna difícil determinar através das leis físicas que o regem (COELHO Antônio e COELHO Leandro, 2015; GONÇALVES, 2014).

Segundo Aguirre (2000) [28], existem três considerações capazes de simplificar o modelo mas que devem ser reavaliadas se o desempenho for considerado inadequado:

- Linearidade: supõe que o sistema a ser modelado se comporta de forma aproximadamente linear. Essa suposição é verificada com a observação do sistema em uma faixa estreita de operação. Existem situações nas quais essa consideração não é adequada.

- Invariância no tempo: implica que a dinâmica que está regulando a evolução temporal é a mesma. Infelizmente a maior parte dos sistemas reais variam ao longo do tempo.

- Concentração de parâmetros: resulta em equações diferenciais ordinárias e pressupõe que as variáveis de interesse variam apenas com o tempo e não no espaço. Entretanto equações diferenciais ordinárias descrevem o sistema tanto em tempo quanto no espaço.

Os dados experimentais de entrada e saída do sistema identificado são denominados dados de identificação e são obtidos através da aquisição simultânea da resposta do sistema $y(t)$, a um sinal específico de entrada $u(t)$. De acordo com método de identificação pretendido, os dados podem ser extraídos no domínio da frequência ou do tempo (GONÇALVES, 2014) [27].

As etapas de um problema de identificação (Figura 1) de sistemas são:

- Testes dinâmicos e coleta de dados;

- Escolha da representação matemática a ser usada;
- Determinação da estrutura do modelo;
- Estimação de parâmetros
- Validação do modelo.

As etapas apresentadas acima são necessárias tanto para sistemas lineares quanto para sistemas não lineares, sendo a forma de implementação das mesmas a principal diferença, obedecendo as características do sistema (CUNHA, 2011; AGUIRRE, 2000).

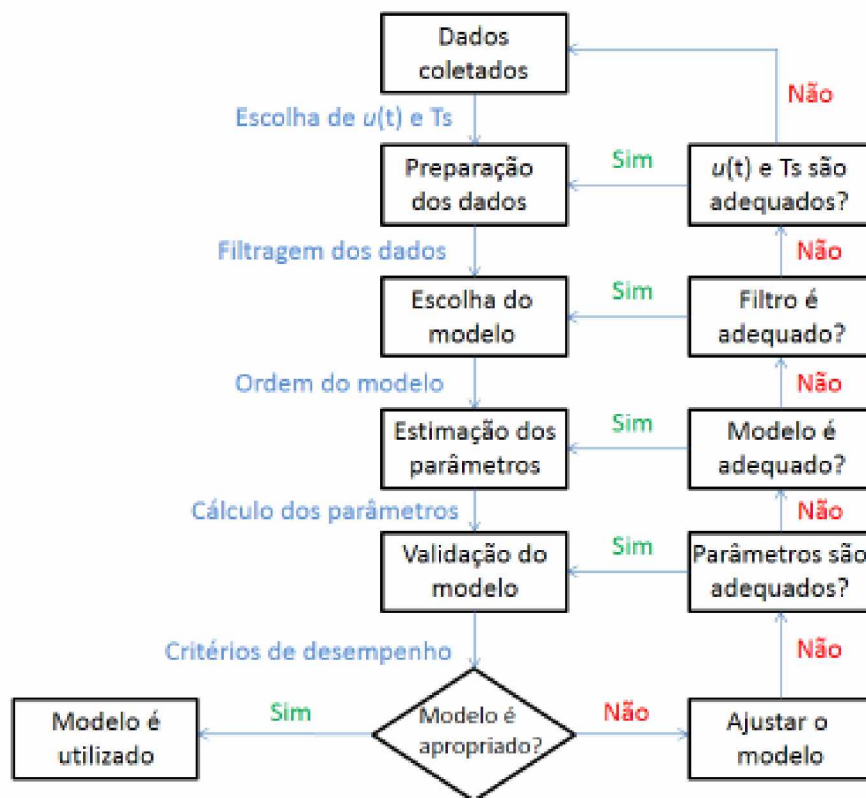


Figura 1. Fluxograma das principais etapas de um processo de identificação de sistemas. Fonte: Gonçalves (2014) [27]

Durante a fase de coleta de dados, é importante garantir que as condições experimentais sejam favoráveis, ou seja, baixo ruído, ausência de perturbações significativas e a maior quantidade de riqueza possível nos dados de entrada e saída (E/S) sobre as propriedades do sistema. Além disso, a escolha do sinal a ser utilizado na entrada do sistema é um fator decisivo na qualidade do modelo que será obtido. O sinal de entrada é responsável por excitar as

dinâmicas internas na faixa de operação pretendida, juntamente com a taxa de amostragem. Um sinal mal projetado pode ocasionar uma validação deficiente do modelo (COELHO Antônio e COELHO Leandro, 2015; GONÇALVES, 2014).

Após a aquisição e preparação dos dados, determina-se uma estrutura matemática apropriada para a modelagem podendo ser, contínua ou discreta (GONÇALVES, 2014) [27]. Os modelos contínuos normalmente envolve a resolução de equações diferenciais enquanto os modelos discretos correspondem à solução de equações diferença (COELHO Antônio e COELHO Leandro, 2015) [25]. Essa etapa deve ser fundamentada no conhecimento do processo de identificação e do sistema a ser identificado. Nesse trabalho são usadas apenas estruturas matemáticas discretas, devido as características do processo em estudo.

Algumas representações matemáticas em tempo discreto usam algoritmos conhecidos para a estimação de parâmetros e são especialmente adequadas para a identificação de sistemas. Entre elas estão modelo de resposta ao impulso finita (FIR), modelo auto-regressivo (*AR-autoregressive*), modelo auto-regressivo com entradas externas (*ARX-autoregressive with exogenous inputs*), modelo auto-regressivo com média móvel e entradas exógenas (*ARMAX-autoregressive moving average with exogenous inputs*), modelo auto-regressivo com média móvel (*ARMA-autoregressive moving average*), modelos de erro na saída e modelo *Box-Jenkins* (AGUIRRE, 2000) [28].

Conforme Aguirre (2000) [28] para descrever as representação é usado um modelo geral descrito abaixo:

$$A(q)y(k) = \frac{B(q)}{F(q)}u(k) + \frac{C(q)}{D(q)}v(k) \quad (1)$$

$$y(k) = \frac{B(q)}{F(q)A(q)}u(k) + \frac{C(q)}{D(q)A(q)}v(k)$$

$$y(k) = H(q)u(k) + G(q)v(k)$$

Onde q^{-1} é o operador de atraso, sendo $y(k)q^{-1} = y(k-1)$, $v(k)$ simboliza o ruído branco e $A(q)$, $B(q)$, $C(q)$, $D(q)$ e $F(q)$ os polinômios definidos pelas equações a seguir:

$$\begin{aligned} A(q) &= 1 - a_1q^{-1} - \dots - a_{ny}q^{-ny} \\ B(q) &= 1 - b_1q^{-1} - \dots - b_{nu}q^{-nu} \\ C(q) &= 1 - c_1q^{-1} - \dots - c_{nv}q^{-nv} \end{aligned} \quad (2)$$

$$D(q) = 1 - d_1 q^{-1} - \dots - d_{nd} q^{-nd}$$

$$F(q) = 1 - f_1 q^{-1} - \dots - f_{nf} q^{-nf}$$

A função $H(q)$ em (1) é referida como função transferência do processo enquanto $G(q)$ é a função do ruído.

Na equação de resposta ao impulso finita, o somatório entre a resposta ao impulso, $h(k)$, de um sistema de entrada $u(k)$ resulta na saída do sistema com ruído $e(k)$, conforme equação 3:

$$y(k) = \sum_{j=0}^M h(j)u(k-j) + e(k) \quad (3)$$

A representação matemática FIR pode ser obtida pela equação 1, considerando $A(q)=C(q)=D(q)=F(q)=1$ e $B(q)$ um polinômio arbitrário de ordem M , ou seja, $n_u = M$. Nesse caso a equação acima é reescrita como:

$$y(k) = B(q)u(k) + v(k) \quad (4)$$

Comparando a equação 1 à equação 4, pode-se notar que como $C(q)/D(q)=1$, então $e(k)=v(k)$ caracterizando o ruído $e(k)$ adicionado em $y(k)$ como um ruído branco. Como o ruído é acrescido diretamente na saída, trata-se de um modelo tipo erro na saída. Por outro lado, tanto a função transferência do processo $B(q)$ quanto a do ruído possuem o polinômio $A(q)=1$ como fator comum, o que caracteriza esse modelo também como erro na equação.

O modelo auto regressivo com entradas exógenas (ARX) pode ser escrito a partir do modelo geral (equação 1), presumindo-se $C(q)=D(q)=F(q)=1$ e $A(q)$ e $B(q)$ polinômios arbitrários:

$$A(q)y(k) = B(q)u(k) + v(k) \quad (5)$$

Esse modelo é classificado como pertencendo à classe de modelos de erro na equação, uma vez que $v(k)$ aparece diretamente na equação. Ao contrário de FIR, o ruído que aparece adicionado na saída, $e(k)=v(k)/A(q)$, não é branco.

Já o modelo ARMAX é obtido, tomando-se $D(q)=F(q)=1$ enquanto $A(q)$, $B(q)$ e $C(q)$ são representados por polinômios arbitrários (equação 6).

$$A(q)y(k) = B(q)u(k) + C(q)v(k) \quad (6)$$

Ou alternativamente,

$$y(k) = H(q)u(k) + e(k) \quad (7)$$

Onde $e(k)$ é um ruído não branco e definido como: $e(k) = \frac{C(q)}{A(q)}v(k)$.

Como no modelo ARX, o ARMAX pertence à classe de modelo de erro na equação, sendo que, nesse caso, o erro é modelado como um processo de média móvel, e o ruído adicionado na saída é modelado como ruído branco filtrado pelo filtro: $C(q)/A(q)$ (ARMA).

O modelo ARMA é representado da mesma forma que ARMAX, porém quando não há sinais exógenos, ou seja, quando $u(k)=0$. Então, a equação 6 é reescrita da seguinte forma:

$$A(q)y(k) = C(q)v(k) \quad (8)$$

Ou, optativamente,

$$y(k) = G(q)v(k) \quad (9)$$

Sendo que $G(q)$, função de transferência do ruído, quantifica como o processo aleatório branco $v(k)$ influi na saída $y(k)$.

Mesmo considerando que esse modelo não possui entradas externas, é possível interpretar o processo $v(k)$ como a entrada do sistema e com isso entender a saída $y(k)$ como uma versão filtrada da “entrada” $v(k)$ com o uso do filtro $G(q)$.

Modelos do tipo erro na saída podem escritos na forma da equação geral, mas com o polinômio $A(q)=1$, ou seja, pode-se dizer que esses modelos possuem o polinômio $A(q)$, como fator comum nas funções de transferência do processo e do ruído. Pode-se obter um exemplo simples da equação 1 considerando $A(q)=C(q)=D(q)=1$ e $B(q)$ e $F(q)$ polinômios arbitrários:

$$y(k) = \frac{B(q)}{F(q)}u(k) + v(k) \quad (10)$$

Como pode ser observado na equação 10, o ruído branco adicionado à saída justifica o nome desta classe de modelos.

O modelo de Box-Jenkins pode ser obtido a partir do modelo geral, declarando $A(q)=1$ e os demais polinômios arbitrários.

$$y(k) = \frac{B(q)}{F(q)}u(k) + \frac{C(q)}{D(q)}v(k) \quad (11)$$

Nesse modelo as funções de transferência do sistema e do ruído definidas como $B(q)/F(q)$ e $C(q)/D(q)$ respectivamente, são independentemente parametrizadas, ou seja, não possuem parâmetros comuns.

O modelo AR depende somente das saídas anteriores do sistema sendo o mais popular dentro os métodos paramétricos para a estimativa do espectro de potência. O valor atual da série temporal depende dos valores anteriores, sendo esse grau de dependência definido pela ordem do modelo. Este vem sendo utilizado com êxito em várias pesquisas que envolvem o processamento de sinais biomédicos e pode gerar a representação de um movimento oscilatório, como por exemplo o tremor, excitado por um ruído branco (AGUIRRE, 2000; ANDRADE, 2000).

De acordo com Cunha (2011) [26], o modelo AR pode ser representado pela seguinte equação:

$$y(k) = \sum_{i=1}^n \varphi_i^T(k) \theta_i + e(k) \quad (12)$$

Sendo:

$$\varphi = [y(k-1) \ y(k-2) \ \dots \ y(k-n)] \quad (13)$$

Onde:

- φ é o vetor de regressores que contém os valores coletados de saída do sistema a ser identificado e $y(k)$ e n são os sinais de saída e a quantidade de regressores de saída, respectivamente (conforme 13);

- θ é o vetor de parâmetros que serão estimados conforme a estrutura determinada;

- $e(k)$ é o erro de predição calculado pela diferença entre a resposta do sistema identificado e o sistema real (CUNHA, 2011) [26].

A obtenção de um bom modelo depende da escolha adequada da ordem do mesmo. Essa determinação significa estabelecer qual é a ordem necessária para caracterizar o sistema com determinado grau de exatidão ou encontrar um ponto de equilíbrio entre a facilidade de estabelecer o modelo e a sua exatidão. Nesse contexto, existem dois tipos de modelos: subparametrizados e sobreparametrizados, no qual o primeiro possui menos parâmetros do que

o necessário para representar a dinâmica do processo enquanto o segundo forma um modelo complexo desnecessário que descreve também o ruído que incidiu sobre o sistema durante a coleta. O ideal é utilizar o menor número de parâmetros possíveis para a descrição do modelo (GONÇALVES, 2014) [27].

A estimação e ajuste de parâmetros é feito através de algoritmos. Esses descrevem um procedimento numérico que determina os valores dos parâmetros do modelo, além de um processo de otimização no qual o melhor modelo é aquele que melhor se ajusta às medidas para um dado critério (COELHO Antônio e COELHO Leandro, 2015) [25].

Caso o erro não esteja na faixa desejada, é necessário ajustar os parâmetros do modelo estimado de modo que a diferença entre a saída do sistema e a do modelo seja mínima, de acordo com um critério estabelecido (COELHO Antônio e COELHO Leandro, 2015) [25]. O procedimento para esse ajuste está apresentado na Figura 2.

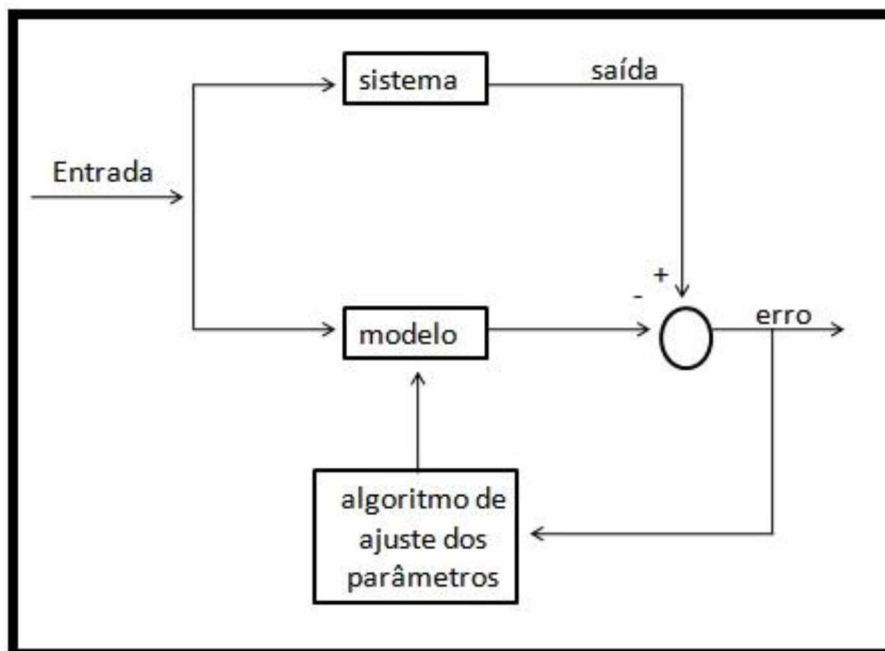


Figura 2. Diagrama de Ajuste do Modelo de Identificação. Fonte: Adaptado de Coelho Antônio e Coelho Leandro (2015) [25]

Após a estimação paramétrica, o modelo do sistema é validado. Nesse ponto, técnicas de validação do modelo são usadas com objetivo de qualificar o seu desempenho. Entre as técnicas de validação destaca-se a comparação das respostas do sistema real com àquelas resultantes do modelo obtido. Essa comparação gera um erro, o qual caracteriza o modelo como adequado se estiver nos valores preestabelecidos ou se a resposta do modelo estimado representa

corretamente a resposta do sistema (COELHO Antônio e COELHO Leandro, 2015; CUNHA, 2011).

2.4.1. Identificação Paramétrica

Existem várias formas de se calcular os parâmetros do modelo AR. Entre eles, os principais são: método de auto correlação, método de covariância, e os métodos adaptativos que incluem os mínimos quadrados (*LMS- Least Mean Square*) e os mínimos quadrados recursivos (*RLS- Recursive Least Square*). Além dessas técnicas tradicionais, métodos alternativos, como redes neurais recorrentes estão sendo utilizadas para essa aplicação (CUNHA, 2011; ANDRADE, 2000).

Os métodos de auto correlação e covariância, requerem a estacionaridade do sinal para o cálculo apropriado dos parâmetros do modelo. Essa limitação pode ser solucionada calculando-se esses coeficientes através de algoritmo adaptativo para cada amostra, o qual é muito usado no processamento de sinais biomédicos (ANDRADE, 2000) [29].

O princípio dos mínimos quadrados foi formulado por Karl Friedrich Gauss no final do século 18 com intuito de prever a trajetória de planetas e cometas a partir das observações realizadas. Ele estabeleceu que os parâmetros desconhecidos de um modelo matemático devem ser escolhidos de modo que minimizem a soma dos quadrados da diferença entre os valores reais e os valores calculados, multiplicados por números que medem o grau da precisão sendo que quanto mais precisa a medida, melhor a sua ponderação (COELHO Antônio e COELHO Leandro, 2015) [25].

A diferença entre o LMS e o RLS é o tipo de identificação sendo o primeiro considerado off-line e o segundo on-line. Quando a estimação de parâmetros é feita de modo off-line, o processo é excitado pelos sinais de teste de entrada e as medidas de entrada e saída são armazenadas para aplicação e posterior avaliação dos algoritmos de estimação não recursivos. Todo o cálculo dos parâmetros é realizado em um momento sendo o tempo de avaliação diferente daquele em que acontece o ensaio. Já a identificação on-line é um processo iterativo via computador que faz uso de métodos recursivos, os quais necessitam de pouca memória e são capazes de atualizar a estimação dos coeficientes do modelo a cada período de amostragem (COELHO Antônio e COELHO Leandro, 2015; CUNHA, 2011).

Conforme Figura 3, no estimador dos mínimos quadrados recursivos, a cada período de amostragem, novas medidas disponíveis são utilizadas com o modelo atual para calcular um novo erro de amostragem ($\varepsilon(t)$). Por exemplo, no instante $(t+1)$, novas medidas de entrada

($u(t+1)$) e saída ($y(t+1)$) são geradas pelo sistema. Para se obter as novas estimativas $\hat{\theta}(t-1)$, atualiza-se as estimativas calculadas anteriormente ao invés de recalcular o estimador dos mínimos quadrados (COELHO Antônio e COELHO Leandro, 2015) [25].

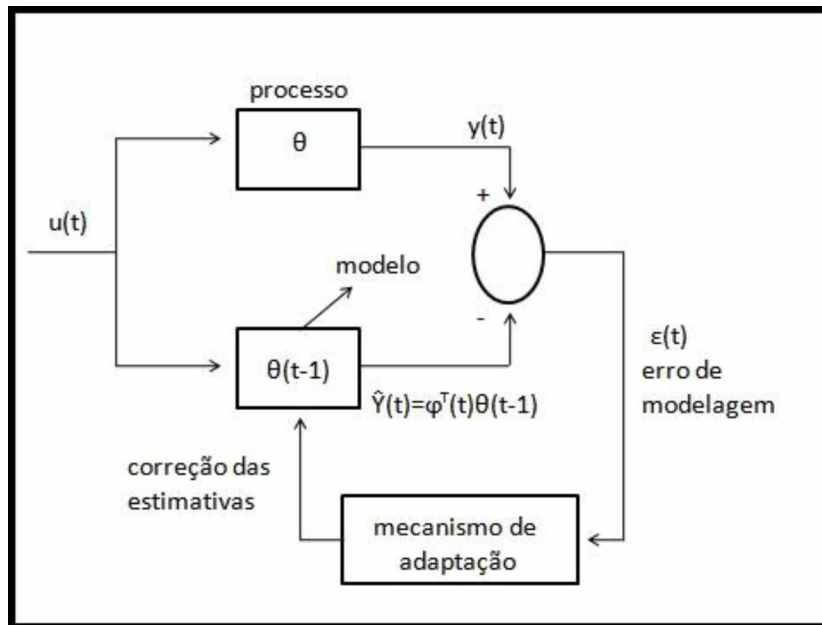


Figura 3. Procedimento do estimador dos Mínimos Quadrados Recursivos. Fonte: Adaptado de COELHO Antônio e COELHO Leandro (2015) [25].

O estimador recursivo de mínimos quadrados é dado pelas seguintes equações:

$$K_k = \frac{P_{k-1}\varphi_k}{\varphi_k^T P_{k-1} \varphi_k + 1} \quad (14)$$

$$\hat{\theta}_k = \hat{\theta}_{k-1} + K_k [y(k) - \varphi_k^T \hat{\theta}_{k-1}] \quad (15)$$

$$P_k = P_{k-1} - K_k \varphi_k^T P_{k-1} \quad (16)$$

Onde K_k é a matriz de ganho que é calculada de forma a garantir que $\hat{\theta}_k$ seja uma boa estimativa, $\hat{\theta}_k$ é o vetor de parâmetros estimado e P_k é a matriz de covariância (COELHO Antônio e COELHO Leandro, 2015) [25].

2.5. Reconhecimento de Padrões

O reconhecimento de padrões (RP) consiste na discriminação de amostras de objetos ou indivíduos e, posteriormente, na classificação ou categorização correta de amostras futuras. O processo de reconhecimento de padrão é dividido na etapa de treinamento (aprendizagem) e na de reconhecimento (classificação). No modelo de aprendizagem é necessário mapear as

características entre os grupos de treinamento avaliando os padrões conforme as categorias. A classificação usa as características e o modelo de aprendizagem para atribuir uma categoria a um padrão. Em seguida é realizada a avaliação de confiança nas decisões (STANGE e NETO, 2010) [30].

Na fase de aprendizagem é necessário mapear as características entre os grupos de treinamento avaliando os padrões conforme as categorias. O objetivo é definir, a partir de um conjunto de exemplos de treinamento, um conjunto de regras que define um padrão. O resultado do treinamento é um modelo de aprendizagem que define o classificador. Na etapa de reconhecimento, o classificador é utilizado com a finalidade de agrupar os dados de classificação de acordo com critérios definidos durante sua construção. Nessa fase, um padrão não classificado é inserido para ser reconhecido de acordo com o modelo de aprendizagem definido durante o treinamento (STANGE e NETO, 2010) [30].

Objetos ou indivíduos são caracterizados por conjuntos de atributos, sendo que cada atributo possui um valor. O atributo refere-se a características significativas do objeto que se deseja classificar. Podem ser categóricos, binários, ordinais ou contínuos. Nem todas as características terão valor significativo para o reconhecimento, por exemplo, na definição de uma espécie animal a análise do sexo não ajudaria na definição da espécie. Além disso, alguns atributos significativos podem não ser suficientes para reconhecer padrão, o que faz necessário a análise de mais rótulos. Porém essa adição causa custo computacional alto que pode ser evitado com a escolha de somente atributos apropriados que permitam melhor diferenciação entre os objetos. Para isso, se faz necessário conhecer o problema (SOARES E SANT'ANA, 2006) [31].

Há duas formas de se classificar o padrão: classificação supervisionada e classificação não supervisionada. Na primeira classificação o padrão de entrada é identificado como um membro de uma classe pré-definida pelos padrões de treinamento. Na classificação não supervisionada o padrão é associado a uma classe que é aprendida baseada na similaridade entre os padrões de treinamento (STANGE e NETO, 2010; SOARES E SANT'ANA, 2006).

A utilização e projeto de métodos de análise e classificação de padrões tornou-se mais simples com o avanço e disponibilidade de vários recursos computacionais.

O projeto de um sistema de reconhecimento de padrões, é descrito, principalmente, pelas seguintes etapas:

- Extração de características dos objetos a classificar, o que inclui a aquisição de dados e pré-processamento;

- Seleção das características mais discriminantes, a qual descreve como os dados serão representados;
- Construção do classificador que tomarão as decisões de agrupamento.

Os algoritmos de extração e seleção de peculiaridades são essenciais para auxiliar na classificação, visto que, na maioria das vezes, existem milhares de características para caracterizar uma amostra. Esses agem reduzindo a dimensionalidade de características de padrão de uma forma que o caráter discriminante que identifica esses atributos não seja perdido (SOARES E SANT'ANA, 2006) [31].

Dentre os domínios de problemas que utilizam o reconhecimento de padrões, estão: mineração de dados, automação industrial, reconhecimento biométrico, sensoriamento remoto e reconhecimento de voz, classificação de sinais ECG, EEG e EMG, reconhecimento manuscrito (ANDRADE, 2000) [29].

Mesmo havendo diferentes áreas de aplicação, existem etapas essenciais do projeto de reconhecimento que são idênticas para todas. A classificação automática de padrões é representada pelo modelo básico na Figura 4.

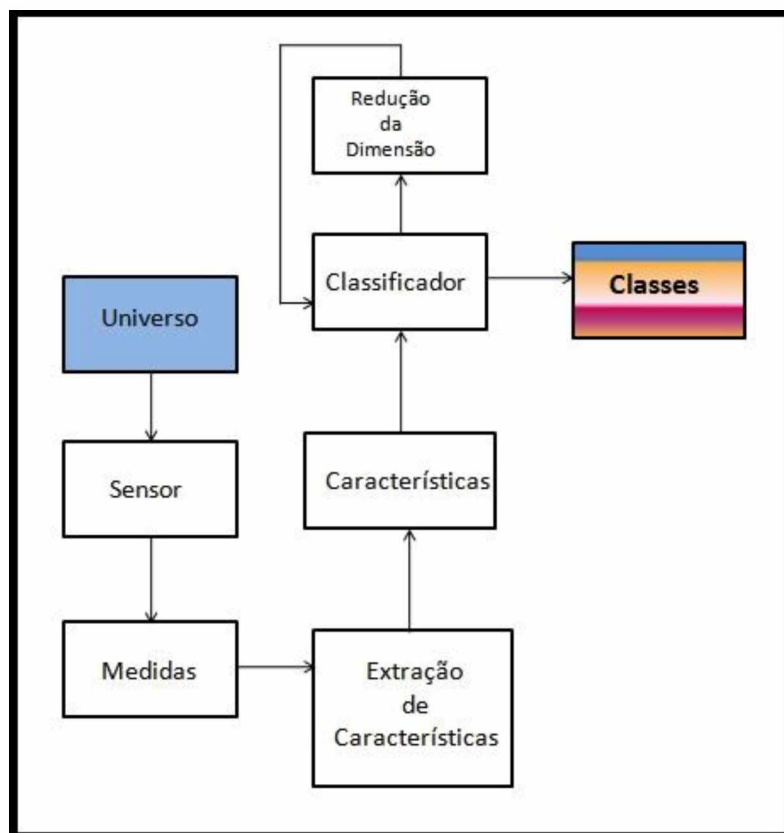


Figura 4. Fluxograma do modelo básico para classificação automática de padrões. Fonte: Adaptado de Andrade (2000) [29].

Na Figura 4 é representado um processo de reconhecimento, onde as características do objeto analisado são coletadas por um sensor que capta dados fisicamente mensuráveis. Um extrator de atributos converte as medidas em informações verificáveis pela máquina que irão formar um vetor multidimensional. Como na maior parte das vezes esse vetor é muito grande ou irrelevante e redundante, um procedimento de redução de dimensionalidade é executado. O conjunto obtido é então processado por um classificador que qualifica os objetos do universo em classes (ANDRADE, 2000) [29].

As técnicas de classificação de padrões são diversas: abordagem estatística, abordagem sintática, abordagem neuronal e abordagem difusa. Dentre essas várias técnicas, a abordagem estatística computacional foi escolhida para a realização desse trabalho.

2.5.1. Análise estatística

Em reconhecimento de padrão com abordagem estatística, um padrão consiste em um conjunto de atributos conhecido como vetor de características d-dimensional. Para estabelecer as fronteiras de decisão são utilizadas noções da teoria de decisão estatística. O treinamento, para aprendizagem do sistema e a classificação para testes constituem os dois modos de operação do sistema de reconhecimento desse método (SOARES E SANT'ANA, 2006) [31].

A partir do MATLAB e da caixa de ferramentas de estatística e de aprendizagem de máquinas é possível analisar e explorar os dados do problema para escolher qual o algoritmo de classificação é mais adequado, treinar e simplificar o selecionado e finalmente verificar sua eficiência.

O aplicativo *ClassificationLearner* é uma ferramenta do MATLAB que treina modelos para classificar os dados. A partir deste, é possível supervisionar a aprendizagem usando vários classificadores, além de explorar os dados, selecionar recursos, especificar esquemas de validação, treinar modelos e avaliar os resultados. Essa ferramenta fornece algoritmos de aprendizado para realização de treinamentos automatizados a fim de encontrar qual o melhor tipo de modelo de classificação, incluindo: máquinas de vetor de suporte (*SVMs- Support Vector Machines*), árvores de decisão, K- vizinhos mais próximos (*KNN- k-nearest neighbor*), *K-means*, modelos de mistura Gaussiana, entre outros (MATHWORKS. Statistics and Machine Learning Toolbox; MATHWORKS.Classification Learner). Após análises foi determinado que a melhor ferramenta estatística para os dados coletados seria KNN.

2.5.2. Algoritmo KNN

O algoritmo de classificação KNN é formado pelo critério de similaridade, o qual possui grande influência no desempenho do método. Esse critério é formado pela função de distância e pelo critério de seleção, que determina como serão selecionados os k vizinhos de um documento de teste. Um critério de seleção elege, por exemplo, 5 documentos de treino que possuem maior similaridade ao documento de teste (SANTOS, 2009) [34].

Para a classificação KNN deve-se especificar o número de vizinhos próximos que se deseja usar na classificação, a métrica da distância (*euclidean*, *cityblock*, *cosine*, *correlation*, *hamming*) e a regra para decidir como classificar o grupo teste (*nearest*, *random*, *consensus*) (MATHWORKS. Classification KNN class) [13].

As etapas desse algoritmo são realizadas da seguinte forma:

- um vetor d -dimensional de teste é recebido pelo algoritmo que classifica as linhas da matriz de dados em grupos, baseados nos agrupamentos de linha informados para o treinamento;
- o vetor d -dimensional e a matriz de treinamento devem possuir a mesma quantidade de colunas;
- no algoritmo do KNN existe um vetor conhecido como grupo no qual os valores distintos definem a quantidade de agrupamentos de linhas na matriz treinamento;
- treinamento e grupo devem ser vetores com o mesmo número de linhas;
- classificação KNN trata ausência de número (*NaN- Not a Number*) ou vetores com caracteres vazios em grupo como falta de valor e ignora essas linhas na matriz de treinamento;
- após o treinamento é gerado um vetor classe que indica qual grupo cada linha da amostra de teste foi atribuído.

Após a classificação, realiza-se uma análise para avaliar o desempenho do modelo quanto a separação dos grupos em estudo.

2.5.3. Análise de classificação

Em conjunto com a análise estatística foi utilizado uma técnica de validação cruzada para validar os resultados e avaliar a capacidade de generalização do modelo. Essa busca estimar o quão preciso é o modelo, avaliando o seu desempenho para um novo conjunto de dados.

O conceito dessa técnica é o particionamento aleatório dos dados em 3 partes: conjunto para treinamento, usado para fazer a aprendizagem do algoritmo com estimação dos parâmetros,

conjunto de validação e o conjunto de testes que avalia a generalização do algoritmo e valida o modelo.

Existem diversas formas para a realização do particionamento dados, sendo que os mais conhecidos são: método *holdout*, *K-fold* e *leave-one-out*. O método de validação cruzada *K-fold*, foi o escolhido para esse trabalho (SCHNEIDER. Cross Validation) [35].

O método de validação cruzada denominado *K-fold* divide o conjunto de amostras em k subconjuntos do mesmo tamanho, dos quais um subconjunto é usado para teste enquanto os restantes ($k-1$) são utilizados para estimação dos parâmetros e para o cálculo da acurácia do modelo. Esse procedimento é executado k vezes e um erro médio é calculado em todos os k ensaios. Cada dado fica em um conjunto de testes exatamente uma vez, e fica em um conjunto de treinamento $k-1$ vezes. Ao finalizar as k iterações, é calculada a acurácia sobre os erros encontrados obtendo assim uma medida confiável sobre a capacidade do modelo de retratar o processo gerador de dados. A variância da estimativa resultante é reduzida quando k aumenta.

A desvantagem desse método é que o algoritmo de treinamento deve ser atualizado a partir do zero k vezes, o que gera maior custo computacional para fazer a avaliação. Por outro lado, sua vantagem é a liberdade de decisão do tamanho de cada conjunto de teste sendo que a divisão dos dados é feita de forma aleatória em um conjunto de teste e de treinamento k vezes diferentes (SCHNEIDER. Cross Validation) [35].

Capítulo 3

ESTADO DA ARTE

O presente capítulo descreve o estado da arte referente aos estudos relacionados à captação, quantificação, análise e diagnóstico da Doença de Parkinson dos sinais obtidos de pacientes com tremor.

3.1. Métodos para avaliação objetiva do Movimento Humano

Objetivando-se encontrar formas objetivas para o diagnóstico da doença de Parkinson, vários estudos fazem uso de sistemas formados por sensores inerciais e eletromiografia (MACHADO, 2016; LEYMOYNE et al., 2009; DAI et al., 2015; NIAZMAND et al., 2011; 12; BISWAS et al., 2016).

De acordo com LEYMOYNE et al. (2009) [9] existem dois problemas quando se utiliza a escala UPDRS. O primeiro problema é a interpretação qualitativa da escala, o que gera variações entre as análises de vários clínicos. O segundo é a característica ordinal que não faz uso de variável temporal, o que pode gerar erros visto que a DP consiste em atributos temporais. Com isso, o acelerômetro pode ser capaz de abordar os dois problemas com o objetivo de quantificar os atributos da DP e também detectar características temporais do tremor. A partir desse conhecimento, esse trabalho faz uso de um simulador de tremor de mão em indivíduo sem Doença de Parkinson para quantificar o tremor e de um dispositivo vestível com acelerômetro sem fio capaz de gerar um banco de dados do paciente com a progressão da doença. Esses dados possibilitam otimizar a dosagem dos medicamentos ou melhorar os parâmetros DBS, em tempo real. Esse sensor inercial faz a gravação das medidas, durante 5 ensaios, com tremor simulado e dos dados com a mão na posição estática. Após amostras de ambos sinais é possível ver um grande contraste entre os gráficos de representação.

Outro estudo que faz uso de acelerômetros para analisar o tremor foi descrito em (SHAH et al., 2013) [21]. Ele empregou esses sensores para medir a aceleração do tremor em 6 pacientes

durante suas cirurgias DBS, com o objetivo de avaliar mudanças quantitativas. As gravações da aceleração iniciaram-se antes dos testes de estimulação e continuaram durante as estimulações de amplitude. A análise dos dados do pós-operatório revelaram que as medidas de aceleração são muito sensíveis à mudança no tremor e que elas podem ser usadas para identificar clinicamente amplitudes de medidas efetivas.

O estudo de revisão de Machado (2016) [4], com a finalidade de visualizar e avaliar as diferenças motoras entre grupos de indivíduos com Doença de Parkinson submetidos a tratamento medicamentoso e à Estimulação Profunda do Cérebro, fez uso de análises objetivas a partir de sinais captados por sensores inerciais (acelerômetro, giroscópio e magnetômetro) e eletromiográficos. Um total de 38 sujeitos participou da coleta de dados, sendo um pouco de cada grupo, e foi monitorado durante a execução de 3 tarefas dinâmicas e uma tarefa estática. Foi utilizada a extração de características para estimar informações importantes sobre os dados do movimento e da atividade muscular coletados. Os resultados mostraram diferenças visuais e estatísticas para todos os grupos e condições validando as técnicas do estudo como eficiente para a caracterização e discriminação dos grupos.

Já em Biswas et al. (2016) [22] é proposta uma técnica que faz uso de acelerômetro e giroscópio para potencial uso como ferramenta de acesso à progressão da reabilitação em patologias neurodegenerativas. Os sensores localizados próximos ao pulso coletam dados durante exercícios prescritos para classificar e detectar qual melhor movimento pode ser usado para avaliar a reabilitação usando o cluster de classificação k-means.

O estudo de Basu et al. (2013) [12] apresentou um método para prever e atenuar o tremor em pacientes com Doença de Parkinson utilizando medidas externas, não invasivas, de eletromiografia e de acelerômetro e o DBS ON- OFF. O intervalo de tempo para ligar e desligar o DBS são regulados a partir do conjunto de parâmetros calculados pelo EMG e acelerômetro, em tempo real. Esse intervalo é otimizado para cada paciente. Foram realizados 91 testes em 4 pacientes com DP o qual obteve acurácia de 80,2% e em 4 pacientes com tremor essencial com acurácia de 85,7%.

Um sistema ambulatorial para quantificar o tremor e a bradicinesia em pacientes com Doença de Parkinson é proposto em Salarian et al. (2007) [23], no qual uma unidade de detecção que inclui miniaturas de giroscópio foi fixada em cada antebraço. Algoritmos para detectar e quantificar o tremor e a bradicinesia foram propostos e validados a partir de dois estudos clínicos, onde em um deles os indivíduos realizaram 17 atividades diárias típicas e no outro moveram-se livremente durante as medições. Esse estudo apresentou evidências de que a

avaliação objetiva, precisa e simultânea do tremor e da bradicinesia pode ser obtida em movimentos livres de pacientes com DP durante suas atividades diárias.

Não foram encontrados estudos consideráveis com o uso do magnetômetro para avaliar tremor. Em Biswas et al. (2016) [22], por exemplo, o magnetômetro foi excluído da análise pelo risco de ter suas medidas afetadas pela presença de possíveis materiais ferromagnéticos no ambiente doméstico.

Os métodos descritos pelos trabalhos citados alcançaram êxito nos resultados, obtendo assim, alternativas objetivas para diagnósticos da doença de Parkinson e quantificação do tremor para análises de dosagem de medicação e de definição dos parâmetros do DBS.

Capítulo 4

MÉTODOS E MATERIAIS

Nessa seção é apresentada a metodologia de uma abordagem para a realização automática da diferenciação entre os grupos analisados com base em modelagem paramétrica dos sinais coletados pelo acelerômetro.

4.1. Dados utilizados

As medidas utilizadas nesse trabalho foram obtidas de um estudo (MACHADO, 2016) [4] no qual 38 sujeitos participaram, sendo 10 indivíduos saudáveis (SS), 16 indivíduos que sofrem da doença de Parkinson tratados com levodopa (SDP) e 12 indivíduos que sofrem da doença de Parkinson tratados com estimulação profunda do cérebro (SEPC). Para esse estudo a proposta é classificar o indivíduo em saudável ou com tremor parkinsoniano, então a análise será feita somente entre os grupos SS e SDP.

Os sujeitos do grupo experimental SS consiste em três homens e sete mulheres com idades variando entre 23 e 64 anos, enquanto o grupo SDP possui seis homens e dez mulheres com idades variando entre 47 e 92 anos. Todos esses voluntários foram recrutados na Universidade Federal de Uberlândia. Os critérios de inclusão para o grupo SDP foram a presença de problemas motores provenientes da DP, tratamento com levodopa e ausência de neuroestimulador. Para o grupo SS o critério de inclusão foi a ausência de quaisquer problemas motores (MACHADO, 2016) [4].

O sistema responsável pela coleta de dados é composto por uma luva vestível que possui dois conjuntos de sensores inerciais fixados e dois conjunto de sensores de EMG. Dentre o conjunto de sensores fixados na luva desse sistema está o acelerômetro de três eixos (sensibilidade mínima de ± 2 g). O acelerômetro localizado no sensor 1 é o mensurador dos dados utilizados nesse projeto (Figura 5). Ele afere forças de aceleração linear em três direções ortogonais e é capaz de capturar o movimento pela ação da gravidade e muscular, incluindo

tremores. Atualmente, é o sensor mais comum para a avaliação de distúrbios motores e possui uma grande correspondência com os dados obtidos através da UPDRS (ANDRADE et al., 2013) [8].



Figura 5. Luva com os dois conjuntos de sensores inerciais utilizada na aquisição de dados sendo que os dados considerados nesse trabalho foram coletados a partir do acelerômetro presente no conjunto 1. Fonte: Machado (2016) [4].

Nos procedimentos da pesquisa, os sujeitos repetiram por cinco vezes uma sequência de quatro tarefas sendo que cada uma delas teve a duração de dez segundos. A tarefa utilizada nesse estudo foi somente aquela em que o paciente permanece com o cotovelo em extensão, sem a realização de movimentos voluntários (Figura 6) (MACHADO, 2016) [4].



Figura 6. Tarefa realizada pelo paciente com cotovelo em extensão, sem realização de movimento voluntário. Fonte: Machado (2016) [4].

O hardware criado por MACHADO (2016) [4], que recebe os sinais medidos, possui a capacidade de coletar pulsos através de um botão externo que é controlado pelo pesquisador. Esse gerador de pulsos foi excitado no início e final de cada uma das cinco séries de repetições e também durante a troca de atividade dentro da série, a fim de registrar o início e fim de cada

tarefa. Tal procedimento auxiliou a análise desse projeto devido ao janelamento dos dados que especificou o início e fim da tarefa com o braço estático em extensão nas 5 repetições.

O sinal de cada sensor inercial teve sua componente resultante estimada, filtrada e livre da influência de tendências lineares e não lineares (MACHADO, 2016) [4].

A Figura 7 apresenta a simulação do sinal coletado pelo acelerômetro presente no sensor 1, após ter sido filtrado e normalizado. A quarta parte de cada análise, indicada pela seta alaranjada, corresponde aos sinais resultantes da tarefa utilizados nesse projeto.




Figura 7. Simulação do sinal obtido pelo acelerômetro do sensor 1 usados no projeto com os dados do paciente 16.

4.2. Obtenção dos Modelos Matemáticos

Os modelos matemáticos foram obtidos nesse estudo utilizando-se os sinais captados pelo acelerômetro como dados para um método de modelagem de séries temporais. Esse método é baseada na obtenção do sinal atual com uma combinação linear de seus valores passados (ANDRADE, 2000) [29].

A estrutura matemática utilizada no processo de identificação foi a do modelo Auto Regressivo, que depende somente das saídas anteriores do sistema em questão, conforme equação 12. O AR foi escolhido devido às características dos dados utilizados e ao êxito em várias pesquisas que envolvem processamento de sinais biomédicos.

Os parâmetros do modelo foram estimados de forma adaptativa, para cada amostra, usando um algoritmo conhecido como método dos mínimos quadrados recursivos (AGUIRRE, 2000) [28]. Esse algoritmo ajusta os parâmetros a cada amostra adquirida, tendo a resposta atual do algoritmo como uma previsão baseada em parâmetros gerados pelo sistema (CUNHA, 2011) [26].

Os parâmetros estimados no método RLS possuem as características de interesse do sinal original e informações sobre as propriedades do movimento para compreensão das medidas e reconhecimento de padrões do tremor parkinsoniano.

O algoritmo para parametrização do modelo foi desenvolvido no software MATLAB, o qual gera, para cada voluntário, equações matemáticas com 2 a 10 parâmetros para cada uma das cinco repetições da tarefa.

Após gerar todos os modelos para cada sujeito (45 equações por sujeito), se fez necessário calcular a média das 5 repetições da tarefa para cada quantidade de parâmetros, nos cinco intervalos de tempo medidos. Com isso cada voluntário obteve apenas uma equação matemática para cada quantidade de parâmetros.

A relação dessas características encontradas após calcular a média é exemplificada na Tabela 1, com base nos dados do voluntário 16 que não apresenta doença de Parkinson. A coluna NP caracteriza o número de regressores utilizados na parametrização e θ os valores dos parâmetros, sendo que os números que os acompanham representam qual a posição dos mesmos na equação.

Tabela 1. Parâmetros obtidos para o sujeito 16 a partir da modelagem AR

NP	θ_1	θ_2	θ_3	θ_4	θ_5	θ_6	θ_7	θ_8	θ_9	θ_{10}
2	0.87492	0.12508								
3	0.86816	0.07675	0.05509							
4	0.85973	0.07032	0.04837	0.11834						
5	0.84006	0.07794	0.06075	0.02875	0.17152					
6	0.81933	0.08051	0.05239	0.03678	0.08042	0.10894				
7	0.80587	0.07187	0.05056	0.02873	0.07232	0.02044	0.10883			
8	0.79369	0.07214	0.05908	0.02520	0.07734	0.01397	0.02940	0.09779		
9	0.78632	0.06827	0.05714	0.03058	0.07628	0.01927	0.02775	0.04655	0.06332	
10	0.77957	0.06603	0.06081	0.03124	0.07038	0.02128	0.03384	0.03964	0.00770	0.08904

Para definir a ordem do modelo Auto Regressivo que é capaz de melhor diferenciar os indivíduos saudáveis dos indivíduos com a doença de Parkinson, analisando os parâmetros, foi utilizado um classificador *KNN* e validação cruzada para análise de classificação.

4.3. Classificador KNN e Validação Cruzada

Os coeficientes do modelo AR contêm informações sobre as características do sinal. Então, nesse projeto, o cálculo dos coeficientes desse modelo para o sinal do acelerômetro, gera informações sobre o movimento da área analisada. Para diferentes valores de aceleração medidos, diferentes conjuntos de parâmetros são identificados. Com isso, esses parâmetros constituem um conjunto de características para o reconhecimento e classificação dos diferentes padrões do movimento (ANDRADE, 2000) [29].

A partir da ferramenta *ClassificationLearner* (MATHWORKS. Classification Learner) [33] do MATLAB, que examina a aprendizagem de vários classificadores, concluiu-se de modo empírico que o método de classificação *KNN* possui melhor desempenho em acurácia na maioria dos testes para separação dos grupos analisados. Esse método atingiu 84,6% de acurácia no teste com 2 parâmetros (Figura 8).

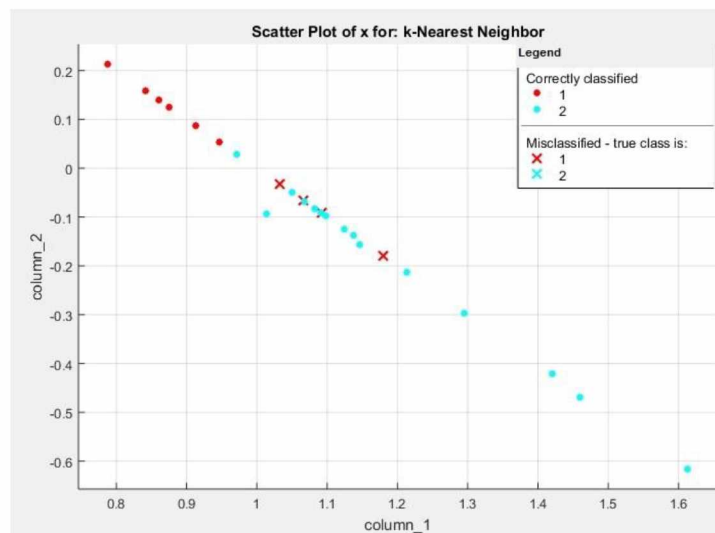


Figura 8. Gráfico de Desempenho do Método de Classificação KNN no ClassificationLearner a partir da análise dos dados estudados utilizando o modelo AR com 2 parâmetros.

O classificador foi implementado no MATLAB para qualificar cada modelo AR usando *KNN* com validação cruzada $K\text{-fold}=5$. Com isso, o modelo foi treinado com 4 subgrupos sendo 1 usado para teste.

O valor do *K-fold* foi definido devido a menor taxa de erro de classificação, revelando assim uma medida mais confiável sobre a capacidade do modelo de representar o processo gerador dos dados.

A métrica usada no cálculo de distância entre dois pontos foi a Euclidiana, definida por:

$$dpq = \sqrt{(p_1 - q_1)^2 + (p_2 - q_2)^2 + \dots + (p_n - q_n)^2} \quad (17)$$

Onde:

- dpq é a distância euclidiana entre os pontos P e Q;
- $P = (p_1, p_2, \dots, p_n)$ e $Q = (q_1, q_2, \dots, q_n)$ são vetores de pontos em um espaço euclidiano n-dimensional.

4.4. Índices de Desempenho gerados pelo Classificador KNN

Os indicadores de desempenho foram usados para medir se os objetivos determinados foram atingidos, ou seja, se os indivíduos foram corretamente classificados. Esse indicador é qualificável através de um índice que retrata a performance do processo como todo ou em partes. Os índices usados proporcionaram maior exatidão na tomada de decisão do melhor modelo para o estudo proposto e detalhamento sobre as falhas e sucessos do processo.

A cada execução do algoritmo de classificação implementado no MATLAB foram calculados os seguintes indicadores de desempenho para a análise da classificação dos indivíduos em cada um dos grupos: verdadeiro positivo (VP), falso positivo (FP), verdadeiro negativo (VN), falso negativo (FN). O verdadeiro positivo representa o diagnóstico positivo para o indivíduo pertencente à classe analisada enquanto o verdadeiro negativo acusa um diagnóstico negativo para o paciente que não pertence àquela classe. O falso positivo representa o diagnóstico positivo de um indivíduo que não possui as características do grupo analisado e falso negativo o diagnóstico negativo daqueles que possuem características que se enquadram no grupo.

A partir das medidas citadas, calculou-se o valor de sensibilidade (S), especificidade (E), precisão (P) e acurácia (A) além do desvio padrão (σ) de cada medida.

O desvio padrão calculado foi o amostral, pois os dados utilizados se referem a uma pequena parcela da população da qual os resultados foram inferidos.

$$S = \frac{VP}{VP+FN} \quad (18)$$

$$E = \frac{VN}{VN+FP} \quad (19)$$

$$P = \frac{VP}{VP+FP} \quad (20)$$

$$A = \frac{VP+VN}{VP+VN+FP+FN} \quad (21)$$

$$\sigma = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1} \quad (22)$$

Onde:

- x_i são os dados da série analisada;
- \bar{x} representa a média aritmética da série analisada;
- n é o tamanho da população

A medida de sensibilidade de um método (equação 18) reflete o quanto este é eficaz em identificar corretamente, dentre todos os indivíduos avaliados, aqueles que realmente apresentam a característica de interesse. Assim, no caso de portador da Doença de Parkinson, a sensibilidade mede o quanto o método é capaz de identificar os voluntários que de fato apresentam doença. Já a especificidade (equação 19) reflete a competência do método em identificar corretamente os indivíduos que não apresentam a condição de interesse.

A precisão (equação 20), para a engenharia, simboliza a dispersão do conjunto de valores que se obtém a partir das medições com a mesma característica, sendo que quanto menor a dispersão maior é a precisão. Enquanto isso, a acurácia (equação 21) é a proximidade do valor experimental com o valor real, a qual apresenta uma proporção direta na autenticidade do resultado obtido com o valor medido.

O desvio padrão (equação 22) indica a dispersão em torno da média amostral de uma variável aleatória, e foi usado a fim de propiciar maior confiabilidade na classificação. Quanto maior for o desvio-padrão, maior será a dispersão em relação à média, quanto menor o desvio-padrão, menor o desvio haverá em relação à média.

Para cada quantidade de parâmetros do modelo AR, o código de classificação foi executado cinco vezes para se obter uma média e um desvio padrão de todos os indicadores de desempenho. Esse procedimento foi realizado a fim de se obter um resultado mais confiável visto que a cada execução os conjuntos de dados para treinamento e teste podem ser alterados.

Capítulo 5

DISCUSSÃO E RESULTADOS

Neste capítulo os resultados originados da aplicação das técnicas propostas e descritas na seção anterior são apresentados e discutidos.

5.1. Visualização dos Resultados da Modelagem Matemática

Afim de verificar se os modelos Auto Regressivos utilizados, com método recursivo para estimação dos parâmetros, geraram sinais que representam adequadamente o sinal real adotou-se duas formas de visualização. A primeira é a visualização gráfica, conforme Figura 9, na qual se observa que o modelo identificado acompanha o comportamento do sistema real, o que faz com que ele se torne válido. Nessa figura, o sinal do modelo identificado refere-se aos dados do indivíduo 16 utilizando o modelo com 2 parâmetros. Esse procedimento foi realizado para todos os voluntários em cada ordem do modelo.

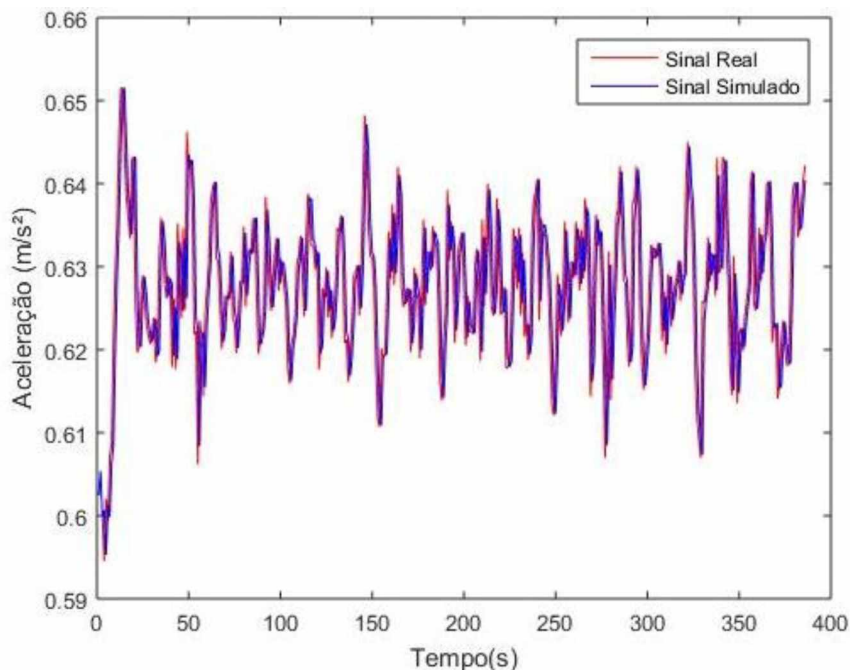


Figura 9. Sinal Simulado pelo modelo AR de Segunda Ordem X Sinal Real para dados do sujeito 16.

A outra forma de validação é a partir do cálculo do erro quadrático médio (EQM). Esse erro é calculado a partir das medidas reais e das medidas geradas pelo modelo identificado para cada indivíduo em cada quantidade de parâmetros. A equação utilizada para medir esse erro é descrita a seguir.

$$EQM = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n} \quad (23)$$

Na equação 23, y_i representa os dados coletados, \hat{y}_i são os dados estimados e n é o número de observações. Se y_i é igual a \hat{y}_i o EQM é igual a 0, o que leva a concluir que quanto mais próxima a medida estimada for da medida real, menor será o erro.

Fazendo-se a média dos erros quadráticos para cada quantidade de parâmetros, considerando todos os pacientes, foi possível perceber que a diferença entre o sinal real e o sinal estimado foi irrelevante, aproximadamente 10^{-3} , o que valida o método da identificação usado para a análise dos dados (Figura 10).




Figura 10. Gráfico da Média do Erro Quadrático Médio para cada modelo matemático.

5.2. Resultados da Classificação de Padrões

Para facilitar a análise dos resultados através dos índices de desempenho, algumas tabelas são apresentadas para a realização de comparações.

A Tabela 2 apresenta os valores médios dos índices de desempenho após as 5 execuções do algoritmo, para cada um dos modelo, obtidas a partir do classificador *KNN*. O Grupo 1 simboliza pacientes saudáveis, o Grupo 2 pacientes com a doença de Parkinson e NP o número de parâmetros. A Tabela 3 mostra o valor do desvio padrão desses índices.

Os valores da Tabela 2 representam a quantidade de indivíduos classificados em cada um dos índices para cada grupo e quantidade de parâmetros. Considerando o Grupo 2, por exemplo, o verdadeiro positivo e o falso negativo indicam o número de sujeitos avaliados nesses índices de um total de 16 (sujeitos diagnosticados com doença de Parkinson). Nessa mesma análise, as medidas obtidas para o verdadeiro negativo e falso positivo representam a quantidade de sujeitos classificados nesses indicadores de um total de 10 (sujeitos diagnosticados como neurologicamente saudáveis).

Tabela 2. Valor médio dos indicadores de desempenho do classificador KNN para cada modelo Auto Regressivo.

NP	Grupo	VP	FP	VN	FN
2	1	5.8	0.8	15.2	4.2
2	2	15.2	4.2	5.8	0.8
3	1	7	4.8	11.2	3
3	2	11.2	3	7	4.8
4	1	5.4	3.2	12.8	4.6
4	2	12.8	4.6	5.4	3.2
5	1	7	3.8	12.2	3
5	2	12.2	3	7	3.8
6	1	7.6	2.8	13.2	2.4
6	2	13.2	2.4	7.6	2.8
7	1	4.4	5.6	10.4	5.6
7	2	10.4	5.6	4.4	5.6
8	1	6	7.4	8.6	4
8	2	8.6	4	6	7.4
9	1	7.6	7.4	8.6	2.4
9	2	8.6	2.4	7.6	7.4
10	1	8	7.2	8.8	2
10	2	8.8	2	8	7.2

Tabela 3. Valor do desvio padrão de cada um dos índices de desempenho para cada modelo AR.

NP	Grupo	Desvio Padrão(VP)	Desvio Padrão(FP)	Desvio Padrão(VN)	Desvio Padrão(FN)
2	1	0.447	0.447	0.447	0.447
2	2	0.447	0.447	0.447	0.447
3	1	1.225	0.447	0.447	1.225
3	2	0.447	1.225	1.225	0.447
4	1	0.894	0.837	0.837	0.894
4	2	0.837	0.894	0.894	0.836
5	1	0.707	0.837	0.837	0.707
5	2	0.837	0.707	0.707	0.837
6	1	1.342	0.447	0.447	1.342
6	2	0.447	1.342	1.342	0.447
7	1	0.894	1.949	1.949	0.894
7	2	1.949	0.894	0.894	1.949
8	1	1.225	1.516	1.516	1.225
8	2	1.516	1.225	1.225	1.516
9	1	1.516	1.516	1.516	1.516
9	2	1.516	1.516	1.516	1.516
10	1	0.707	0.837	0.837	0.707
10	2	0.837	0.707	0.707	0.837

Como a classificação dos dados é em apenas dois grupos as medidas de VP de um deles é correspondente às medidas de VN do outro, por exemplo. Com isso, para se evitar observações redundantes, todo o estudo nessa etapa é feito baseado no Grupo 2.

Como pode-se observar na Tabela 2, examinando o mesmo grupo, as medidas do indicador FN são complementos das medidas do VP enquanto os valores FP são complementos dos valores VN. Portanto, para a obtenção de alguns resultados sobre a quantidade de parâmetros do modelo AR na classificação correta dos indivíduos, as análises dessas tabelas serão realizadas com base nas medidas VP e VN.

A partir dessas considerações e das tabelas apresentadas, a equação matemática com 2 parâmetros foi a que demonstrou o melhor índice VP com 15.2 indivíduos classificados corretamente de um total de 16. Por outro lado, as equações que apresentaram o pior índice VP foram as com 8 e 9 parâmetros, classificando apenas 8.6 sujeitos. Já para o indicador VN a melhor equação foi para NP igual a 10, que resultou da classificação de 8 indivíduos saudáveis em um total de 10. O pior modelo foi com número de parâmetros igual a 7, que classificou apenas 4.4 sujeitos. Os resultados da análise isolada desses dois índices são apresentados, de forma simplificada, na Tabela 4.

Tabela 4. Melhores modelos matemáticos a partir da avaliação do índices: verdadeiro positivo e verdadeiro negativo.

	VP	VN
NP/ Melhor Porcentagem	2/ 15.2±0.447	10/ 8±0.707
NP/ Pior Porcentagem	8 e 9/ 8.6±1.516	7/ 4.4±0.894

A partir da verificação anterior, pelas medidas verdadeiro positivo e verdadeiro negativo, a escolha é ou pelo modelo de 2 parâmetros ou pelo de 10 parâmetros para melhor distinção dos dois grupos. Porém é necessário fazer uma análise geral, visto que ao mesmo tempo que se classifica corretamente os sujeitos pertencentes ao grupo em questão também é necessária uma boa classificação dos sujeitos no outro grupo estudado. Portanto, para se fazer essa análise, é necessário calcular a porcentagem de acerto para cada indicador de desempenho. Esse cálculo é realizado dividindo todos os valores obtidos em VP por 16 e todos os valores de VN por 10. A partir das porcentagens obtidas, encontrou-se a relação das médias dos indicadores VP e VN para cada modelo matemático, as quais podem ser observadas na Tabela 5.

Tabela 5. Porcentagem das medidas verdadeiro positivo e verdadeiro negativo e a média dos dois índices.

NP	%VP	%VN	Média de %VP e %VN
2	95%	58%	76.5%
3	70%	70%	70%
4	80%	54%	67%
5	76.25%	70%	73.12%
6	82.5%	76%	79.25%
7	65%	44%	54.5%
8	53.75%	60%	56.87%
9	53.75%	76%	64.87%
10	55%	80%	67.5%

A Tabela 5 mostra que ao analisar os dois indicadores, o modelo com 6 parâmetros é o mais adequado para essa classificação enquanto o com NP igual a 7 não evidenciou uma boa performance.

Para auxiliar na análise do melhor modelo para classificação entre indivíduos neurologicamente saudáveis e indivíduos acometidos pela doença de Parkinson, a Tabela 6 apresenta as médias de desempenho da sensibilidade, especificidade, precisão e acurácia, calculadas a partir dos indicadores obtidos pelo classificador KNN. A Tabela 7 indica as respectivas medidas de desvio padrão.

Tabela 6. Medidas de desempenho calculadas a partir dos resultados do classificador KNN para análise do melhor modelo AR.

NP	Grupo	Sensibilidade	Especificidade	Precisão	Acurácia
2	1	0.58	0.95	0.881	0.81
2	2	0.95	0.58	0.787	0.81
3	1	0.7	0.7	0.591	0.7
3	2	0.7	0.7	0.794	0.7
4	1	0.54	0.8	0.628	0.7
4	2	0.8	0.54	0.736	0.7
5	1	0.7	0.762	0.649	0.738
5	2	0.762	0.7	0.803	0.738
6	1	0.76	0.825	0.729	0.8
6	2	0.825	0.76	0.851	0.8
7	1	0.44	0.65	0.45	0.569
7	2	0.65	0.44	0.648	0.569
8	1	0.6	0.537	0.448	0.561
8	2	0.537	0.6	0.684	0.561
9	1	0.76	0.537	0.508	0.623
9	2	0.537	0.76	0.798	0.623
10	1	0.8	0.55	0.527	0.646
10	2	0.55	0.8	0.815	0.646

Tabela 7. Valores do desvio padrão para cada uma das médias de desempenho calculadas.

NP	Grupo	Desvio Padrão(S)	Desvio Padrão(E)	Desvio Padrão(P)	Desvio Padrão(A)
2	1	0.045	0.028	0.067	0.027
2	2	0.028	0.045	0.019	0.027
3	1	0.122	0.028	0.047	0.050
3	2	0.028	0.122	0.075	0.050
4	1	0.089	0.052	0.099	0.063
4	2	0.052	0.089	0.048	0.063
5	1	0.071	0.052	0.064	0.050
5	2	0.052	0.071	0.047	0.050
6	1	0.134	0.028	0.047	0.050
6	2	0.028	0.134	0.077	0.050
7	1	0.089	0.122	0.074	0.069
7	2	0.122	0.089	0.047	0.069
8	1	0.122	0.095	0.071	0.070
8	2	0.095	0.122	0.067	0.070
9	1	0.152	0.095	0.041	0.050
9	2	0.095	0.152	0.115	0.050
10	1	0.071	0.052	0.043	0.050
10	2	0.052	0.071	0.058	0.050

A partir das tabelas 6, vários resultados podem ser extraídos. Primeiramente, ao analisar o índice sensibilidade nota-se que o modelo matemático construído a partir de 2 parâmetros possui maior sensibilidade enquanto os modelos com NP igual a 8 e 9 possuem menor sensibilidade. Já para especificidade a equação com número de parâmetros igual a 10 apresentou o maior valor significativo para esse índice e o menos significativo foi com NP igual a 7.

Realizando a comparação entre os valores de sensibilidade e especificidade em todos os modelos apresentados na Tabela 6, é possível concluir que a melhor relação de custo benefício entre os dois índices foi encontrada em NP igual a 6, no qual S vale 0.825 ± 0.028 e E vale 0.76 ± 0.134 .

Tabela 8. Melhores e Piores medidas de Sensibilidade e Especificidade para os modelos observados.

	Sensibilidade	Especificidade
NP/Melhores Valores	2/ 0.95 ± 0.028	10/ 0.8 ± 0.071
NP/Piores Valores	8 e 9/ 0.537 ± 0.095	7/ 0.44 ± 0.089

Todos esses resultados já eram de se esperar baseando-se nas conclusões dos índices de VP e VN e nas equações 6 e 7, que mostram a forte relação da sensibilidade e especificidade com o verdadeiro positivo e verdadeiro negativo, respectivamente.

Conclusões qualitativas do sistema também podem ser alcançadas com a verificação da precisão e da acurácia. Ponderando os resultados da Tabela 6, é visto que o modelo mais preciso e o menos preciso é o com 6 e 7 parâmetros, respectivamente. O modelo com 6 parâmetros também é encontrado como um dos que obtiveram uma das melhores medidas para acurácia junto com o de NP igual a 2, o qual apresentou melhor desempenho em 1.25%. Por outro lado, a equação com 7 parâmetros, assim como na medida de precisão, foi classificada como um das piores com base nesse índice com o valor muito próximo ao do modelo com 8 parâmetros. Essa conclusão é apresentada na Tabela 9.

Tabela 9. Conclusão da análise dos melhores modelos considerando a precisão e a acurácia.

	Precisão	Acurácia
NP/Melhores Valores	6/ 0.851 ± 0.077	2 / 0.81 ± 0.027 e 6/ 0.80 ± 0.050
NP/Piores Valores	7/ 0.648 ± 0.047	7 / 0.569 ± 0.069 e 8/ 0.561 ± 0.070

Fazendo uma avaliação geral, observa-se que os modelos com 2 e 6 parâmetros foram os que apresentaram as melhores classificações em relação à diferenciação de indivíduos com

doença de Parkinson de indivíduos saudáveis enquanto os modelos com 7 e com 8 parâmetros mostram os piores resultados. Dessa forma, foram feitas as seguintes análises:

- Modelo com 2 parâmetros:
 - classificou a maioria dos sujeitos doentes no grupo 2 (95%) e, ao mesmo tempo, apresentou o menor desvio padrão para essa medida (VP);
 - como consequência do melhor VP, possui a maior sensibilidade;
 - possui a maior medida de acurácia na classificação (0.81) e, ao mesmo tempo, a menor dispersão das amostras para essa medida.

- Modelo com 6 parâmetros:
 - apresentou a melhor porcentagem para a relação da média de VP e VN, conseqüentemente a melhor correlação entre as medidas de sensibilidade e especificidade;
 - possui menor medida de desvio padrão para a medida de sensibilidade.
 - é o modelo mais preciso;
 - possui a segunda maior medida de acurácia na classificação (0.8).

- Modelo com 7 parâmetros:
 - classificou a maioria dos sujeitos saudáveis no grupo 2 (56%), ou seja, não possui bom VN;
 - possui a pior porcentagem para a relação da média de VP e VN e, ao mesmo tempo, a maior dispersão das amostras para o índice VP;
 - é o menos específico na classificação, não apresentando capacidade para classificar corretamente os sujeitos que não pertencem à classe avaliada;
 - é o modelo com menor medida de precisão,
 - possui a menor medida de acurácia.

- Modelo com 8 parâmetros:
 - um dos modelos que pior classificou os sujeitos com doença de Parkinson no grupo 2 (53.75%), ou seja, possui o menor VP e conseqüentemente a pior sensibilidade;
 - é o modelo com menor medida de acurácia e, ao mesmo tempo, maior medida de desvio padrão para esse índice;

A distinção automática, gerada pela classificação dos parâmetros do modelo AR, entre um grupo de indivíduos saudáveis e um grupo de sujeitos com a DP pode ocasionar benefícios nos diagnósticos e na administração do progresso da doença, evitando falsos resultados.

Os resultados apresentados levam em consideração a diferenciação entre voluntários com Doença de Parkinson tratados com levedopa e voluntários saudáveis, sem avaliar os subtipos da doença. Os diferentes subtipos geram diferentes padrões de movimento na execução da tarefa o que pode influenciar na classificação do sujeito. Além disso, as variações no tratamento com medicamento podem causar instabilidade nos resultados do movimento, por depender do tempo de administração.

Capítulo 6

CONCLUSÕES

O método proposto por esse estudo pode, potencialmente, discriminar os grupos de sujeitos acometidos pela Doença de Parkinson e sujeitos neurologicamente saudáveis excluindo a subjetividade dos métodos e escalas sujeitas às falhas humanas. Portanto, o sistema desenvolvido é uma alternativa para as técnicas objetivas de avaliação recentemente estudadas, o qual faz uso de identificação de sistemas a partir de medidas obtidas por acelerômetro.

A escolha pelos dados coletados em (MACHADO, 2016) [4] gerados pelo acelerômetro foi devido à utilização desse sensor na maioria dos estudos de referências do estado da arte para avaliar as características do tremor e à sua abordagem prática e econômica. O uso dessas medidas já coletas em outro estudo, eliminou a necessidade do processo de seleção dos sujeitos, da formulação do protocolo de coleta e da aprovação pelo comitê de ética para a realização dos experimentos.

A diferença do sistema desenvolvido nesse estudo, quando comparado com outros estudos para diagnóstico e acompanhamento da DP de forma objetiva, é o fato de que esse examina a possibilidade de visualizar e classificar os sinais e características dos indivíduos de forma automática e computacional utilizando os parâmetros correspondentes da modelagem dos dados coletados por acelerômetro.

Após a discussão dos métodos usados e dos resultados obtidos, foi possível observar que os parâmetros do modelo Auto Regressivo portam as características dos padrões dos movimentos, o que os tornam capazes de diferenciar os indivíduos nos dois grupos avaliados. Entretanto, a eficiência dessa discriminação alterou significativamente entre os modelos variando com a quantidade de parâmetros.

Dentre as análises, os modelos Auto Regressivos com 2 e 6 parâmetros foram os que proporcionaram as maiores taxas de sucesso, sendo os mais eficientes para discriminar os dois grupos avaliados.

A representação matemática com 6 parâmetros ainda apresenta vantagens sobre a equação com 2 parâmetros. Essa afirmação é baseada nos valores dos índices de melhor precisão, melhor relação entre a sensibilidade e especificidade e uma acurácia das melhores acurácias, que só é menor que o modelo com 2 parâmetros em 0.008, que corresponde a 1%. Enquanto isso o modelo menos indicado para essa diferenciação é o com 7 parâmetros, por estar presente nas piores medidas de quase todos os índices.

Como trabalhos futuros, recomenda-se incluir no banco de dados uma maior quantidade de amostras tanto de pacientes saudáveis neurologicamente quanto de pacientes com Doença de Parkinson tratados com levedopa. Além disso pode-se ampliar a análise fazendo uso do conhecimento dos diferentes subtipos da doença e da variação no tratamento com medicamento dos voluntários estudados. Com a utilização desses dados a classificação dos indivíduos no grupo esperado poderia ser mais eficaz gerando índices de desempenho com melhores valores.

Diferentes cenários como introdução de pacientes com DP tratados com EPC é uma opção para analisar se os parâmetros gerados pelas equações matemática desse grupo e do grupo com DP tratado com levedopa são capazes de diferenciá-los. Se essa diferenciação acontecer, a classificação dos grupos terá um bom índice de desempenho, o que significa que os parâmetros obtidos conseguem representar as características da aceleração do tremor dos pacientes diferenciando-os apenas pela forma de tratamento.

Referências Bibliográficas

[1] SOUZA, Cheylla Fabricia de Medeiros. A Doença de Parkinson e o Processo de Envelhecimento Motor: Uma Revisão de Literatura. Disponível em: <[http://revistaneurociencias.com.br/edicoes/2011/RN1904/revisao 19 04/570revisao.pdf](http://revistaneurociencias.com.br/edicoes/2011/RN1904/revisao%2019%2004/570revisao.pdf)>.

[2] BORGES, Vanderci; FERRAZ, Henrique Ballalai. Tremores. Revista Neurociências, São Paulo, v. 14, n. 1, p.043-047, jan./mar. 2006.

[3] CHEN, Shin-yuan; TSAI, Sheng-tzung. The Epidemiology of Parkinson's Disease. Tzu Chi Medical Journal. Hualien, p. 73-81. jun. 2010. [https://doi.org/10.1016/S1016-3190\(10\)60044-4](https://doi.org/10.1016/S1016-3190(10)60044-4)

[4] MACHADO, Alessandro Ribeiro de Pádua. Visualização e Classificação de Características para a Discriminação Entre Indivíduos com a Doença de Parkinson Submetidos a Tratamento com Levodopa e Estimulação Profunda do Cérebro. 2016. 91 f. Tese (Doutorado) - Curso de Engenharia Elétrica, Faculdade de Engenharia Elétrica, Universidade Federal de Uberlândia, Uberlândia, 2016.

[5] GOULART, Fátima; PEREIRA, Luciana Xavier. Uso de escalas para avaliação da doença de Parkinson em fisioterapia. Fisioterapia e Pesquisa, Belo Horizonte, v. 11, n. 1, p.1-8, jan. 2005.

[6] RIZZO, G. et al. Accuracy of clinical diagnosis of Parkinson disease: A systematic review and meta-analysis. Neurology, v. 86, n. 6, p. 566-76, feb. 2016. <https://doi.org/10.1212/WNL.0000000000002350>

[7] The Unified Parkinson's Disease Rating Scale (UPDRS): Status and recommendations. Movement Disorders, v. 18, n. 7, p. 738-750, 2003. <https://doi.org/10.1002/mds.10473>

[8] ANDRADE, A. O. et al. Human Tremor: Origins, Detection and Quantification. 2013. Disponível em: <<http://www.intechopen.com/books/export/citation/EndNote/practical-applications-in-biomedical-engineering/human-tremor-origins-detection-and-quantification>>.

- [9] LEMOYNE, R. et al. Quantification of Parkinson's disease characteristics using wireless accelerometers. *Complex Medical Engineering*, 2009. CME. ICME International Conference on, 2009, 9-11 April 2009. <https://doi.org/10.1109/ICCME.2009.4906657>
- [10] DAI, H. et al. Quantitative assessment of parkinsonian bradykinesia based on an inertial measurement unit. 2015. Disponível em: <<https://biomedical-engineering-online.biomedcentral.com/articles/10.1186/s12938-015-0067-8>>. <https://doi.org/10.1186/s12938-015-0067-8>
- [11] NIAZMAND, K. et al. Quantitative evaluation of Parkinson's disease using sensor based smart glove. 2011 24th International Symposium On Computer-based Medical Systems (cbms), [s.l.], p.1-8, jun. 2011. IEEE. <https://doi.org/10.1109/CBMS.2011.5999113>
- [12] BASU, I. et al. Pathological tremor prediction using surface electromyogram and acceleration: potential use in 'ON-OFF' demand driven deep brain stimulator design. *J Neural Eng*, v. 10, n. 3, p. 036019, Jun 2013. <https://doi.org/10.1088/1741-2560/10/3/036019>
- [13] MATHWORKS. Classification KNN class. Disponível em: <<https://www.mathworks.com/help/stats/classificationknn-class.html>>.
- [14] WERNECK, Antônio Luiz S.. Doença de Parkinson: etiopatogenia, clínica e terapêutica. *Revista Hospital Universitário Pedro Ernesto*, [s.i.], v. 9, n. 1, p.1-11, jan./jun. 2010.
- [15] KALIA, Lorraine V; LANG, Anthony E.. Parkinson's disease. *The Lancet*. Toronto, p. 896-912. 29 ago. 2015. [https://doi.org/10.1016/S0140-6736\(14\)61393-3](https://doi.org/10.1016/S0140-6736(14)61393-3)
- [16] JANKOVIC, J. Parkinson's disease: clinical features and diagnosis. *Journal of Neurology, Neurosurgery & Psychiatry*, v. 79, n. 4, p. 368-376, April 2008. <https://doi.org/10.1136/jnnp.2007.131045>
- [17] ALMEIDA, Maria Fernanda Soares de. Análise Temporal da Relação entre o Tremor Fisiológico Cinético e o Envelhecimento com Base em Desenhos Digitalizados da Espiral de Arquimedes. 2011. 166 f. Tese (Doutorado) - Curso de Engenharia Elétrica, Faculdade de

Engenharia Elétrica, Universidade Federal de Uberlândia, Uberlândia, 2011. Disponível em: <<https://repositorio.ufu.br/bitstream/123456789/14292/1/t.pdf>>.

[18] JORGE, Lília Pereira. Acelerometria na Reabilitação do Membro Superior Após-AVC. 2013. 122 f. Dissertação (Mestrado) - Curso de Engenharia Biomédica, Faculdade de Engenharia da Universidade do Porto, Porto, 2013. Disponível em: <<https://repositorio-aberto.up.pt/bitstream/10216/69362/2/25878.pdf>>.

[19] RABELO, Amanda Gomes. Avaliação de Parâmetros Temporais e Inerciais para a Caracterização da Bradicinesia Parkinsoniana Durante a Extensão do Punho. 2016. 49 f. Dissertação (Mestrado) - Curso de Ciências, Faculdade de Engenharia Elétrica, Universidade Federal de Uberlândia, Uberlândia, 2016. Disponível em: <<https://repositorio.ufu.br/bitstream/123456789/18145/1/AvaliacaoParametrosTemporais.pdf>>.

[20] PATEL, S. et al. Monitoring Motor Fluctuations in Patients With Parkinson's Disease Using Wearable Sensors. *Ieee Transactions On Information Technology In Biomedicine*, [s.l.], v. 13, n. 6, p.864-873, nov. 2009. Institute of Electrical and Electronics Engineers (IEEE). <https://doi.org/10.1109/TITB.2009.2033471>

[21] SHAH, A. et al. Using acceleration sensors to quantify symptoms during deep brain stimulation surgery. *Biomedical Engineering / Biomedizinische Technik*, [s.l.], p.1-2, 7 jan. 2013. Walter de Gruyter GmbH. <https://doi.org/10.1515/bmt-2013-4007>

[22] BISWAS, Dwaipayan et al. Recognizing upper limb movements with wrist worn inertial sensors using k-means clustering classification. *Human Movement Science*, [s.l.], v. 40, p.59-76, abr. 2015. Elsevier BV. <https://doi.org/10.1016/j.humov.2014.11.013>

[23] SALARIAN, Arash et al. Quantification of Tremor and Bradykinesia in Parkinson's Disease Using a Novel Ambulatory Monitoring System. *Ieee Transactions On Biomedical Engineering*, [s.l.], v. 54, n. 2, p.313-322, fev. 2007. Institute of Electrical and Electronics Engineers (IEEE). <https://doi.org/10.1109/TBME.2006.886670>

[24] DAI, Houde; D'ANGELO, L. T.. Quantitative assessment of tremor during deep brain stimulation using a wearable glove system. 2013 Ieee International Conference On Sensing, Communications And Networking (secon), [s.l.], p.1-5, 24 jun. 2013. IEEE. <https://doi.org/10.1109/SAHCN.2013.6644965>

[25] COELHO, Antônio Augusto Rodrigues; COELHO, Leandro dos Santos. Identificação de Sistemas Dinâmicos Lineares. 2. ed. Florianópolis: Editora da Universidade Federal de Santa Catarina, 2015.

[26] CUNHA, Márcio José da. Descoberta do Conhecimento em Base de Dados como Ferramenta Aplicada em Processos Sucroalcooleiros. 2011. 128 f. Tese (Doutorado) - Curso de Engenharia Mecânica, Universidade de São Paulo, São Carlos, 2011. Disponível em: <http://www.teses.usp.br/teses/disponiveis/18/18149/tde-20092011-180126/pt-br.php>.

[27] GONÇALVES, Ângelo David Reis. Identificação de sistemas, Modelos de função de transferência. 2014. 172 f. Dissertação (Mestrado) - Curso de Engenharia Electrotécnica e de Computadores, Universidade de Trás-os-montes e Alto Douro, Vila Real, Portugal, 2014. Disponível em: https://repositorio.utad.pt/bitstream/10348/5854/1/msc_adrgoncalves.pdf.

[28] AGUIRRE, L. A. (2000) Introdução à Identificação de Sistemas- Técnicas Lineares e Não Lineares Aplicadas a Sistemas Reais. Belo Horizonte, Editora UFMG.

[29] ANDRADE, Adriano de Oliveira. Metodologia para Classificação de Sinais EMG no Controle de Membros Artificiais. 2000. 124 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Centro de Ciências Exatas e Tecnologia, Universidade Federal de Uberlândia, Uberlândia. Disponível em: <http://www.aoandrade.eletrica.ufu.br/Documents/MainMScDissertation.pdf>.

[30] STANGE, R. L.; NETO, J. J. Reconhecimento de Padrões em Classificadores – Comparação de Técnicas e Aplicações. In: WORKSHOP DE TECNOLOGIA ADAPTATIVA, 4, 2010, São Paulo. Workshop. São Paulo: Laboratório de Linguagens e Técnicas Adaptativas (lta), 2010. p. 63 - 67.

[31] SOARES, Igor Ferreira; SANT'ANA, Izabel Belchote. Classificador de Padrões Usando Redes Neurais de Kohonen.2006. 62 f. Monografia (Especialização) - Curso de Informática, Universidade Católica do Salvador, Salvador, 2006. Disponível em: <<https://pt.slideshare.net/WandersonRocha4/classificacao-de-padres-usando-redes-neurais-de-kohonen>>.

[32] MATHWORKS. Statistics and Machine Learning Toolbox. Disponível em: <<https://www.mathworks.com/products/statistics.html>>.

[33] MATHWORKS. Classification Learner. Disponível em: <<https://www.mathworks.com/help/stats/classificationlearner-app.html>>.

[34] SANTOS, Fernando Chagas. Variações do Método kNN e suas Aplicações na Classificação Automática de Textos.2009. 96 f. Dissertação (Mestrado) - Curso de Ciência da Computação, Instituto de Informática, Universidade Federal de Goiás, Goiânia, 2009. Disponível em: <[http://www.inf.ufg.br/mestrado/sites/www.inf.ufg.br.mestrado/files/uploads/Dissertacoes/Fernando Chagas.pdf](http://www.inf.ufg.br/mestrado/sites/www.inf.ufg.br.mestrado/files/uploads/Dissertacoes/Fernando%20Chagas.pdf)>.

[35] SCHNEIDER, Jeff. Cross Validation. Disponível em: <<https://www.cs.cmu.edu/~schneide/tut5/node42.html>>.