

**UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA
FILHO” FACULDADE DE ENGENHARIA
CAMPUS DE ILHA SOLTEIRA**

BASAKUAU NKOMI NKOSI JÚNIOR

**A ELETROMIOGRAFIA ASSOCIADA À INTELIGÊNCIA ARTIFICIAL NO DIAGNÓSTICO
DE DOENÇAS E NO RENDIMENTO FÍSICO**

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

BASAKUAU NKOMI NKOSI JÚNIOR

**ESTUDO SOBRE A UTILIZAÇÃO DE ELETROMIOGRAFIA E
INTELIGÊNCIAARTIFICIAL NO DIAGNÓSTICO DE DOENÇAS E
FADIGA MUSCULAR**

Dissertação apresentada à Faculdade de Engenharia - UNESP –
Campus de Ilha Solteira, Solteira, como requisito para obtenção
UNESP do título de Mestre em Engenharia título de Elétrica. Área de
Conhecimento: Automação.

Prof. Orientador: Dr. Marcelo Augusto AssunçãoSanches

FICHA CATALOGRÁFICA
Desenvolvido pelo Serviço Técnico de Biblioteca e
Documentação

N738e Nkosi Junior, Basakuau Nkomi.
A eletromiografia associada à inteligência artificial no diagnóstico de
doenças e no rendimento físico / Basakuau Nkomi Nkosi Junior. -- Ilha
Solteira: [s.n.], 2021
68 f. : il.

Dissertação (mestrado) - Universidade Estadual Paulista. Faculdade de
Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2021

Orientador: Marcelo Augusto Assunção
Sanches Inclui bibliografia

1. Eletromiografia. 2. Inteligência artificial. 3. Diagnóstico. 4.
Diagnóstico clínico.


Raiane da Silva Santos

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: UTILIZAÇÃO DE ELETROMIOGRAFIA E INTELIGÊNCIA ARTIFICIAL NO DIAGNÓSTICO DE DOENÇAS E FADIGA MUSCULAR

AUTOR: BASAKUAU NKOMI NKOSI JUNIOR

ORIENTADOR: MARCELO AUGUSTO ASSUNÇÃO SANCHES

Aprovado como parte das exigências para obtenção do Título de Mestre em ENGENHARIA ELÉTRICA, área: Automação pela Comissão Examinadora:

Prof. Dr. MARCELO AUGUSTO ASSUNÇÃO SANCHES
(Participação Virtual) Departamento de Engenharia Elétrica /
Faculdade de Engenharia de Ilha Solteira - UNESP



Prof. Dr. APARECIDO AUGUSTO DE CARVALHO (Participação Virtual)
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira -
UNESP



Prof. Dr. ADALBERTO VIEIRA CORAZZA (Participação Virtual)
Faculdade de Medicina / Universidade Federal de Mato Grosso



Ilha Solteira, 04 de agosto de 2021

DEDICATÓRIA

A Deus, todo poderoso, entrego minhas profundas gratidões pelo fôlego de vida, por permitir que aqui chegasse, por nunca me desamparar, mesmo quando longe e sozinho me sinto, Seu amor me conforta.

A meu pai, Andre Basakuau, assim como a fé que tenho pela divindade, sei que estás sempre comigo, como meu anjo da guarda, amo-te por sentir sua presença em minha vida.

A minha mãe, Ana Nsalambi, pela vida, pelos ensinamentos e por me fazer ser, por intermédio do seu reflexo, o que hoje sou, o meu amor por ti é infinito, por tidaria todas as vidas que tivesse.

“Tudo posso naquele que me fortalece, pois, ainda que eu transborde para o mais longínquo, sozinho nunca estarei, guias-me mesmo de olhos vendados, a ti pertença, pois, pela sua graça vivo” (FILIPENSES, 4).

AGRADECIMENTOS

Aos meus irmãos, Masidivinga Lando, Simão Kitu, Flora Kitu, Anastsia Nsambu, Djeny Basakuau, Harlete Basakuau, que só nós sabemos onde passamos e hoje ao vê-los sorrir enche meu coração de alegria e satisfação e vontade de voar cada vez mais alto; é bom vos ter.

Dedico esse trabalho aos meus pais, Basakuau Nkomi Nkosi e Ana Nsalambi; à minha esposa Charnela Fay Basakuau; aos meus filhos Neveah Kitu Basakuau , Manasse Basakuau Fay, Patricia Fay Makolo e aos meus amigos pelo apoio e carinho, pois vossa força foi essencial para esse passo da minha vida.

Ao meu orientador, o Prof. Dr. Marcelo Augusto Assunção Sanches e ao Prof. Dr. Adalberto Vieira Corazza, por ter me recebido e guiado sabiamente, pelos ensinamentos, simplicidade e humildade, por depositar confiança em mim, mesmo vindo de uma formação de base diferente, muito grato por me transformar.

Ao Prof. Dr. Sérgio Kurokawa, por tratar sábia e pacientemente meu processo para chegar aqui na UNESP de Ilha Solteira, por me receber, me instalar e por me dar todas as diretrizes acadêmicas e não só, jamais me esquecerei daquele abraço e sorriso de boas-vindas na rodovia, junto ao Prof. Dr. José Luiz Pinheiro Melges, que me proporcionou o primeiro roteiro pela cidade e ajuda no processo de instalação aqui em Ilha Solteira.

Ao Prof. Dr. Aparecido, por permitir a minha inserção no grupo de pesquisadores do LIEB, por receber-me carinhosamente, pelos ensinamentos.

Aos meus boss Eng. Fidel Mapuya, Dr Maria de Fatima, Mestre Lutonadioa Mavakala, Mestre MakiësseMavakala, Eng. Moyo Kanivengidio e Mestre Mbunga nzinga David grande companheiro, muito obrigado pelos conselhos, pelos ensinamentos de vida, pela partilha, pelo apoio e força, a vocês vai uma gratidão muito especial. Aos meus amigos em Angola, que sentem minha falta, porém, sempre mandaram energia positiva para que corra tudo bem.

Agradeço à UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”

– UNESP, especialmente ao departamento de Engenharia Elétrica do Campus de Ilha Solteira.

Ao Instituto Nacional de Gestão de Bolsa de Estudo de Angola – INAGBE e a Universidade Kimpa Vita pelo apoio financeiro, por conceder que tudo isso fosse possível, pois, graças a vós o que ontem foi sonho, hoje é realidade, muito grato por tudo.

RESUMO

A inovação tecnológica na área da saúde tem otimizado o desenvolvimento de ferramentas para o Diagnóstico Clínico (DC) e para a Prática Clínica (PC) no ambiente hospitalar e ambulatorial. Com os avanços dos DC, ano após ano, com a utilização de novas técnicas de *Machine Learning* (ML) e *Deep Learning* (DL) aplicadas em suas estruturas, vêm contribuindo diretamente para o avanço da medicina e suas tecnologias nas mais diversas áreas da saúde. Nesta revisão bibliométrica foram incluídos artigos com foco no uso de Inteligência Artificial (IA) para o auxílio de DC em patologias e disfunções através de Eletromiografia (EMG). De início, encontrou-se um total de 78 artigos, sendo eles identificados nas bases de dados da IEEE Xplore, PubMed e Scopus. Foram excluídos artigos duplicados e artigos de outras categorias diferentes de periódicos completos, de jornais e revistas. Foram analisados 27 artigos que utilizaram sinais EMG e IA. No decorrer de um período de 1980 a 1994, a cerca de 14 anos não houve nenhuma publicação que tinha ligação na pesquisa em questão; em 1995, 1996 a frequência foi de um único artigo. Nenhum autor publicou mais de um trabalho durante o período de 1995 até 1996. Os resultados mostraram que a associação de IA e EMG pode auxiliar com eficiência os profissionais de saúde no diagnóstico de doenças e condições clínicas (CC).

Palavras-chave: Eletromiografia. Inteligência artificial. Diagnóstico. Diagnóstico clínico.

ABSTRACT

Technological innovation in the health area has optimized the development of tools for Clinical Diagnosis (CD) and for Clinical Practice (CP) in the hospital and outpatient environment. With the advances of DC year after year with the use of new Machine Learning (ML) and Deep Learning (DL) techniques applied in their structures, they have been directly contributing to the advancement of medicine and its technologies in the most diverse areas of health. This bibliometric review included articles focusing on the use of Artificial Intelligence (AI) to aid CD in pathologies and dysfunctions through Electromyography (EMG). Initially, a total of 78 articles were found and they were identified in the IEEE Xplore, PubMed and Scopus databases. Duplicate articles and articles from categories other than full-length journals, newspapers and magazines were excluded. Twenty-seven articles that used EMG and AI signals were analyzed. During a period from 1980 to 1994, for about 16 years, there was no publication that was linked to my research; in 1995, 1996 the frequency was of a single article. No author published more than one work during a period from 1995 to 1996. The results showed that the association of AI and EMG can efficiently help health professionals in the diagnosis of diseases and clinical conditions (CC).

Keywords: Electromyography. Artificial intelligence. Diagnosis. Diagnosis clinical.

LISTA DE FIGURAS

Figura 1- Máquina de CPM	21
Figura 2 - Máquina de CAM comercial	22
Figura 3 – Ciclo de despolarização e repolarização da membrana muscular	24
Figura 4 – Processo simplificado de aquisição e caracterização de um EMG	25
Figura 5 - Técnicas do Machine Learning mais utilizados na classificação de EMGs.....	27
Figura 6 – Modelo de um neurônio artificial.....	28
Figura 7 – Rede neural com camadas ocultas	29
Figura 8 – Sistema de impedância mecânica-interação máquina de CPM/CAM-paciente...	31
Figura 9 – Modelo de impedância de segunda ordem.....	31
Figura 10 – Frequência dos artigos selecionados por ano.	39
Figura 11 – Frequência dos artigos selecionados a partir de 1975 até 1996.....	48
Figura 12 - Número de citações dos artigos.....	49
Figura 13 – Frequência com que cada métrica é utilizada nos diferentes	50
Figura 14 – Patologias subdivididas.....	52
Figura 15 - Frequência dos Músculos analisados	53
Figura 16 – Técnicas aplicadas para extração de recursos.....	58
Figura 17 - Informações fornecidas pelos classificadores	59
Figura 18 – Frequência das plataformas de software utilizadas nos trabalhos.....	60
Figura 19 - Estado das citações dos artigos revisados entre 1996 e 2021	61

LISTA DE TABELAS

Tabela 1 - Estruturação das palavras chaves os respectivos resultados.	38
Tabela 2 – Histórico das publicações de cada autor.....	41
Tabela 3 – Informações fornecidas por voluntários.	50
Tabela 4 - Hardware e número de canais usados para adquirir EMG.....	54
Tabela 5 – Parâmetros e métricas de trabalhos de inteligência artificial.....	60

SUMÁRIO

1 INTRODUÇÃO	13
1.1 DIAGNÓSTICO CLÍNICO.....	13
1.2 INTELIGÊNCIA ARTIFICIAL.....	15
1.3 INTELIGÊNCIA ARTIFICIAL NA MEDICINA	16
1.3.1 A Inteligência Artificial na medicina do amanhã.....	16
1.3.2 Os benefícios da Inteligência Artificial na medicina.....	17
1.4 ELETROMIOGRAFIA PARA DIAGNÓSTICO.....	17
1.4.1 O que é um eletromiograma	18
1.4.2 Teste feito através da eletromiograma (EMG).....	19
1.4.3 As indicações do eletromiograma (EMG).....	19
1.4.4 O eletromiograma na prática	20
1.5 REVISÃO DA LITERATURA	20
1.5.1 Movimentação passiva contínua.....	20
1.5.2 Movimentação ativa contínua.....	22
1.5.3 Eletromiografia.....	23
1.5.4 Decomposição de um sinal eletromiográfico.....	24
1.5.5 Caracterização de sinais de EMG baseada em IA.....	26
1.5.6 Redes neurais artificiais.....	27
1.5.7 Perceptrons Multicamadas	28
1.5.8 Sistema de Controle	30
1.5.9 Modelagem matemática de uma máquina de CPM / CAM	30
1.5.1 Captação do sinal	32
1.6 OBJETIVOS	33
1.7 ESTRUTURA DA DISSERTAÇÃO	34
2 MATERIAIS E MÉTODO	34
2.1. ESCOLHA DE PALAVRAS-CHAVE	39
2.2 ESCOLHAS DE BANCO DE DADOS	40
3 RESULTADOS	40
3.1 MÉTRICAS.....	49
3.2. VOLUNTÁRIOS	50
3.3 BIOSINAIS, ELETRODOS E SISTEMA DE EMG	51
3.4 PATOLOGIAS.....	51
3.4 MÚSCULO INVESTIGADO.....	52
3.5 EXTRAÇÃO DE CARACTERÍSTICAS	57
3.6 CLASSIFICADORES.....	58

3.7 PLATAFORMAS DE SOFTWARE.....	59
4 DISCUSSÃO	62
5 CONSIDERAÇÕES FINAIS.....	66
REFERÊNCIAS BIBLIOGRÁFICAS.....	67

1 INTRODUÇÃO

1.1 DIAGNÓSTICO CLÍNICO

Segundo Jean Mesué (2002), “o diagnóstico em medicina pode ser definido como um processo analítico de que se vale o especialista ao exame de uma doença ou de um quadro clínico, para chegar a uma conclusão.”

“O diagnóstico é fundamental para a prática médica. É ao mesmo tempo um ato que mobiliza todas as funções do médico: memória, atenção, aptidão para comunicação e exame, julgamento, interpretação. Também é um resultado” (JEAN MESUE, 2002).

O diagnóstico pertence a diretório de cerca de 30.000 doenças da classificação internacional de doenças (CID). O objetivo do diagnóstico é ir do incerto ao possível, depois ao provável e de provável a certo (ou quase). O diagnóstico é redutor, do subjetivo ao objetivo, desde a história do sujeito até o resultado de exames complementares. É uma cristalização obrigatória que define a doença no sentido de “doença”, que apaga a diferença, permite a classificação e facilita o ensino, a transmissão de conhecimento. Nisso, ele vai do particular ao universal. A doença assim definida não tem existência em si. É um processo patológico do qual conhecemos parcialmente as causas, o terreno em que ocorre, os sinais e a evolução. Sua fundação é anatomoclínico, bioclínico (fisiopatológico), parcialmente genético ou em totalidade. Permite o tratamento, condiciona o prognóstico (Hughes Rousset, 1993).

“A medicina segue um procedimento rigoroso na busca de uma patologia para levar a um diagnóstico e, portanto, a um tratamento, seja ele um medicamento, medidas higienodietéticas, reabilitação” (MARION BERTHON, 2020). Neste trabalho, vamos descobrir os passos que cada médico segue para fazer um diagnóstico: a história, o exame físico e eventuais exames complementares:

➤ *A entrevista com o médico: a anamnese*

A primeira coisa que um médico faz ao vê-lo é questioná-lo. Isso é chamado de história. Depois de perguntar sua idade, ele pergunta em uma ordem precisa, da mais ampla a mais precisa:

Quais são seus hábitos de vida? Em termos de profissão, local de vida, tabaco, álcool, sedentarismo, nutrição.

Qual é o seu histórico médico? Em termos de doenças, alergias, operações, deficiências. Ele pode perguntar se certas patologias estão presentes na sua família.

Quais são seus tratamentos atuais, sejam temporários ou crônicos?

Qual é a história da sua doença? Há quanto tempo você tem sintomas, quais são e como evoluíram?

➤ *O exame físico*

Após a anamnese, o exame físico ocorre em 4 etapas:

Inspeção: o médico está te observando.

Palpação: o médico toca e apalpa certas partes do corpo.

Percussão: o médico procura ruídos anormais, por exemplo, batendo na parte de trás das costas.

Auscultação: o médico ouve certos órgãos internos (coração, intestinos, pulmões) com um dispositivo chamado estetoscópio.

➤ *Exames complementares*

Se necessário, o médico pode realizar exames complementares, mas isso não é sistemático. Por exemplo, ele pode medir sua pressão arterial.

Alguns exames exigem mais material. Ou o médico tem as máquinas no consultório, caso em que vai fazer o exame imediatamente ou vai dar uma receita para fazer em um centro dedicado.

Por exemplo, um cardiologista pode fazer uma ultrassonografia do coração no consultório ou pedir que você vá a um centro de imagem. Também pode ser uma tomografia computadorizada, raio-X, ressonância magnética, biópsia, exame de sangue. Os exames adicionais têm como objetivo responder a uma hipótese diagnóstica. Cada exame corresponde a uma hipótese, ou seja, a uma pergunta que o médico se faz. A história, o exame físico e os exames adicionais constituem o exame clínico.

➤ *O diagnóstico médico é verdadeiro?*

A medicina não é uma ciência exata. Os médicos têm uma obrigação de meios, mas não de resultados. O diagnóstico, portanto, não é certo e mesmo os exames com máquinas não permitem ver tudo do corpo humano.

Por vezes, não é possível fazer um diagnóstico, apesar dos exames realizados, porque não respondem às questões colocadas ou porque as respostas são negativas. Os sintomas persistem sem sucesso na identificação da causa. Diz-se que o paciente está em um diagnóstico errôneo.

Porque precisa ser tranquilizada, de saber os detalhes do seu diagnóstico ou porque está prestes a fazer um diagnóstico, uma segunda opinião médica pode ser útil para si. Isso

envolve buscar o conselho de um segundo médico hiperespecialista durante uma consulta física ou on-line.

1.2 INTELIGÊNCIA ARTIFICIAL

De acordo com *encyclopedie larouse* on-line a inteligência artificial (IA) é definido “como um conjunto de teorias e técnicas implementadas para produzir máquinas capazes de simular a inteligência humana”.

O advento do computador trouxe uma grande expansão no tamanho do homem, aumentando sua capacidade de calcular e armazenar grandes volumes de informação em nanossegundos e isso aumentou drasticamente nossa memória e o tempo para recuperar informações. O “aqui e agora” tornou-se o lema do mundo de hoje, caracterizando uma sociedade em rápida e constante mudança (RUSSEL,S. e NORVIG,P., 2003).

De acordo com o pai da inteligência artificial, John McCarthy, e outros nove participantes, pelo Dartmouth College, em Hanover, New Hampshire (RUSSELL; NORVIG, 2013), a inteligência artificial tem como objetivo projetar máquinas que podem pensar. É a inteligência das máquinas. As discussões sobre a importância da inteligência artificial em nossas vidas têm crescido nos últimos anos. Isso é uma bênção ou uma maldição para o futuro da existência humana? Este é um debate contínuo. A ideia de criar inteligência artificial é tornar a vida mais fácil para os humanos. Os pesquisadores de inteligência artificial desejam trazer o quociente emocional para as máquinas junto com a inteligência geral Histoire Cigref (2014).

A utilização de IA tem se mostrado cada vez mais interessante, já que o poder de aprendizado de máquina traz vários benefícios, como a redução significativa dos custos com manutenção dos *softwares*, por exemplo. Russel e Norvig (2013) contam que, além da habilidade de aprender, existem alguns tipos de máquinas com Inteligência Artificial, chamados por eles de Agentes Inteligentes, que possuem habilidades de autonomia de decisão fundamentada numa medida de desempenho. Essas máquinas são compostas ainda por sensores (dispositivos que capturam dados do ambiente externo, como uma câmera ou um termômetro, por exemplo) e atuadores (dispositivos que realizam ações baseadas nos resultados obtidos através do processamento dos dados captados pelos sensores, como um braço mecânico, por exemplo).

Em conformidade com Souza & Souza (2004), as Rede neurais artificial (RNA) foram criadas tendo como base o funcionamento dos neurônios biológicos e sistema nervoso natural do ser humano (RNN), visto que as RNA também são formadas por vários neurônios conectados uns aos outros se comunicando através de sinapses, embora essa seja uma das poucas semelhanças existentes entre RNA e RNN. Ainda, segundo eles, em qualquer modelo

de RNA, desde um mais simples, como o modelo Perceptron (um dos primeiros a surgir) até os mais complexos, como o modelo Multicamadas, os neurônios possuem, basicamente, de um lado algumas entradas que se conectam ao núcleo e do outro lado pelo menos uma saída que transmite o resultado processado com base em um mecanismo de pesos. Os modelos mais simples de RNA utilizam cálculos simples, como somas ponderadas, baseadas nesses pesos, no processo de aprendizado. Segundo Siqueira-Batista *et al.* (2014) o modelo multicamadas faz o uso de camadas ocultas e cálculos com funções mais complexas, tais como a função tangente hiperbólica e a função sigmoideal.

Existem diversos materiais que são usadas na implementação matemática e computacional de aprendizagem de RNA, embora essa aprendizagem seja obtida, de fato, por intermédio de um processo de treinamento por correção de erro, no qual a rede vai corrigindo os erros transmitidos pelos neurônios por meio da modificação dos pesos a cada iteração, tentando aproximar os valores adquiridos na saída a um valor ideal previamente informado, fazendo com que a rede consiga criar um ou mais padrões para identificar novos valores a partir de novos dados de entrada, conta Ambrósio (2002).

1.3 INTELIGÊNCIA ARTIFICIAL NA MEDICINA

De acordo com o Dr. Francisco Neri, a IA destacou algumas das mudanças que está causando na saúde hoje e amanhã. Uma das mudanças da IA é que ela pode aumentar ou substituir a capacidade humana de identificar doenças e oferecer meios de prevenção e tratamento. “Os computadores são capazes de filtrar uma quantidade de informação impossível para os humanos. Por isso conseguem estabelecer relações entre dados de saúde que permitem novos modelos de prevenção e tratamento, impossíveis de oferecer pelo ser humano”, explica. “Neste campo, um dos principais candidatos à aplicação de sistemas de IA é o diagnóstico por imagem. Setores como radiologia, patologia e dermatologia têm usado essa tecnologia para melhorar a velocidade e a precisão dos diagnósticos” (RUSSEL; NORVIG, 2013).

1.3.1 A inteligência artificial na medicina do amanhã

Segundo Berexia (2019), a Inteligência Artificial está no centro da pesquisa na comunidade médica e suas aplicações agora visam aperfeiçoar a qualidade do atendimento para os medicamentos de amanhã. IA se concentra no desenvolvimento de operações assistidas, tratamentos personalizados, acompanhamento remoto de pacientes, ajuda no tratamento do câncer etc., e também em pesquisas mútuas.

1.3.2 Os benefícios da inteligência artificial na medicina

A IA ajuda oncologistas a tomar decisões, capacita pacientes com diabetes, permite maior precisão em imagens médicas e, em última análise, evitará que certos exames sejam considerados “intrusivos” para os pacientes. A Inteligência Artificial lê os prontuários dos pacientes e, graças às informações adicionais que o médico fornece, pode agora dar um diagnóstico e estabelecer várias propostas de tratamento. Soluções baseadas em IA ajudaram a tratar 13 tipos de câncer (BEREXIA, 2019).

No entanto, a Inteligência Artificial não tende a substituir os médicos, mas complementa o julgamento do médico para permitir que ele modifique ou confirme seu diagnóstico. Ele tomará a decisão usando suas qualidades de inteligência relacional e emocional, um aspecto da inteligência que as máquinas não possuem (BEREXIA, 2019).

De acordo com Berexia (2019), IA, por intermédio de algoritmos, auxilia principalmente no desenvolvimento de diagnósticos. Na verdade, a máquina prescreve o mesmo diagnóstico que o médico em 99% dos casos e, em 30% dos casos, oferece um tratamento mais adequado do que o dos especialistas. Consegue detectar o câncer de mama em 89% dos casos, enquanto os especialistas detectam em 73% dos casos. As máquinas também podem detectar ataques cardíacos pelo telefone. Desse jeito, a robótica está estendendo sua teia em muitas áreas da medicina.

“As inovações tecnológicas, como o algoritmo de diagnóstico e outras soluções de inteligência artificial, podem ser utilizadas em diversos trabalhos na área médica” (MOUSTAFA ZOUINAR, 2020).

1.4 ELETROMIOGRAFIA PARA DIAGNÓSTICO

Segundo o dicionário educalingo, a eletromiografia (EMG) é uma técnica de monitoramento da atividade elétrica das membranas excitáveis das células musculares, representando os potenciais de ação deflagrados por meio da leitura da tensão elétrica. O sinal eletromiográfico (EMG) ou eletromiograma é o somatório algébrico de todos os sinais detectados sob a área de alcance dos eletrodos, podendo ser afetado por propriedades musculares, anatômicas e fisiológicas, assim como pelo controle do sistema nervoso periférico e a instrumentação utilizada para a aquisição dos sinais, há três principais métodos utilizados para detecção do sinal de eletromiografia (Williams; Wikins, 1985).

Em conformidade com Landulpho (2003), existem dois tipos de eletrodos utilizados para captar a eletromiografia: os de superfície e os de inserção. Ambos podem ser monopolares ou bipolares e apresentam características específicas para seu uso:

Eletrodos de superfície

- Acesso rápido e simples ao músculo, próprio para evolução de tratamento;

- Músculo superficiais;
- Controle de dispositivos externos, como próteses;
- Em crianças ou indivíduos que rejeitam os eletrodos de inserção;
- Constituição mais comum: prata clorada;
- Indolor e não invasivo.

Eletrodos de inserção tipo agulha

- Detecção de potencial de ação da unidade motora;
- Se necessário, deve ser reposicionado após inserção;
- Mais dolorido, invasivo;
- Eletrodos de inserção tipo fio;
- Diâmetros pequenos e inseridos através de agulhas hipodérmicas, tendem a se deslocar após as contrações;
- Ligas mais comuns: platina, prata, níquel e cromo;
- Indicado para unidades motores e território;
- Menos dolorido que o agulhado, invasivo.

Em conformidade com Estelle (2019), “a eletromiograma, também chamado de eletroneuromiograma, é um teste usado para avaliar o sistema nervoso periférico, ou seja, o funcionamento de nervos e músculos”. Este exame é realizado por um médico e inclui vários tipos de exames. É essencial para o diagnóstico de inúmeras doenças neurológicas e / ou musculares.

1.4.1 O que é um eletromiograma

O eletromiograma (frequentemente denominado EMG) ou eletroneuromiograma, é uma exploração funcional que avalia o funcionamento dos nervos e músculos. Consiste na aplicação de uma fraca corrente elétrica ao nível das fibras nervosas, sensoriais ou motoras, do sistema nervoso periférico. Essa corrente muito fraca (alguns milésimos de ampere) aplicada por um tempo muito curto (um milésimo a um décimo de segundo) causa um impulso nervoso artificial e, portanto, a transmissão de uma mensagem ao longo da fibra nervosa. A resposta ao impulso nervoso é registrada por sensores colocados na pele, na forma de potenciais nervosos ou musculares (correntes elétricas nos nervos ou músculos), transmitidos a um computador (ESTELLE, 2019).

Quando as fibras nervosas são superficiais, a aplicação da corrente é feita por eletrodos posicionados na pele. “Quando as fibras nervosas estão mais profundas, um eletrodo pode ser inserido sob a pele do músculo a ser estudado, mais ou menos profundamente, usando uma agulha especial” (ESTELLE, 2019).

1.4.2 Teste feito através da eletromiograma (EMG)

O estudo das velocidades de condução das fibras motoras, também chamado de medição da velocidade de condução nervosa motora: as fibras motoras transmitem a mensagem nervosa do cérebro aos músculos para realizar um movimento específico. Este teste avalia o número de fibras motoras ativas em uma determinada região. A atividade muscular é registrada em repouso, durante e após a contração muscular (ESTELLE, 2019).

O estudo das velocidades de condução sensorial, também chamada de medida da velocidade de condução nervosa sensitiva: as fibras sensíveis garantem a transmissão das sensações à medula espinhal e ao cérebro, para análise. Este teste permite, em particular, destacar um ataque da bainha de mielina, envolvendo os nervos periféricos.

Os testes de estimulação repetitiva ou estimulação nervosa repetida, são usados para avaliar a confiabilidade da transmissão da mensagem entre os nervos e os músculos, ao longo de uma série de contrações sucessivas.

1.4.3 As indicações do eletromiograma (EMG)

De acordo com Estelle (2019), a eletromiograma é um teste muito útil para o diagnóstico de diferentes doenças, incluindo:

1. Danos nervosos associados a um acidente ou trauma, para determinar com precisão a localização, natureza e extensão das lesões.
2. Neuropatias periféricas, para definir o tipo de neuropatia e direcionar para a causa. De fato, as neuropatias podem ter origens múltiplas, como infecção, doença sistêmica, deficiências nutricionais, diabetes, exposição a substâncias tóxicas, uma doença genética (doença de Charcot-Marie-Tooth) ou mesmo uma origem autoimune. Nas neuropatias, a velocidade de condução dos impulsos nervosos é reduzida nas áreas em questão.
3. Doenças que afetam os neurônios motores (células nervosas motoras da medula espinhal).
4. A miastenia é caracterizada por uma diminuição na resposta muscular durante os testes de estimulação repetitiva.
5. Miopatia

“Podemos dizer que o eletromiograma é o teste de escolha no diagnóstico de doenças neuromusculares, mas pode ser útil em muitos outros cenários. No caso de doenças

nerológicas centrais, o eletromiograma não mostra nenhuma anormalidade porque a EMG detecta apenas anormalidades periféricas” (ESTELLE, 2019).

1.4.4 O eletromiograma na prática

Em harmonia com Estelle (2019), “a eletromiograma é realizado por um médico especialista, na maioria das vezes um neurologista, assistido ou não por um técnico, podendo ser em um departamento de hospital ou consultório especializado. Um exame clínico geralmente precede os testes”.

Dependendo da doença suspeita, um ou mais testes constitutivos do eletromiograma podem ser necessários. Da mesma forma, esses testes são realizados em um único território, por exemplo, as mãos ou em vários territórios (braços, pernas). Dependendo dos músculos a serem estudados, o paciente está sentado ou deitado. A escolha dos testes realizados e dos territórios estudados depende de vários fatores:

1. Os sintomas vivenciados pelo paciente;
2. Os resultados dos exames clínicos;
3. Informação recolhida durante outros exames efetuados.

Normalmente o eletromiograma dura entre 45 e 90 minutos. Nenhuma preparação é necessária antes do exame. Por outro lado, é solicitada a não utilização de nenhum produto cosmético aplicado na pele no dia do exame para não atrapalhar a gravação do sinal. Além disso, nenhuma anestesia é realizada (ESTELLE, 2019).

1.5 REVISÃO DA LITERATURA

Para um melhor entendimento deste estudo, foram necessários compreender conceitos de, pelo menos, das seguintes áreas de conhecimento: Engenharia e medicina. Desta forma, individual sobre os principais tópicos, que juntos se relacionam e formam a fundamentação teórico deste trabalho. Os principais tópicos são: movimento passivo, eletromiografia, caracterização de sinais de EMG baseados em inteligência artificial, um tópico sobre o sistema de controle e, por fim, uma rápida passagem sobre um sistema genérico de identificação e controle baseado em EMG. Esses tópicos serão abordados mais detalhadamente neste referencial teórico.

1.5.1 Movimentação passiva contínua

A Movimentação Passiva Contínua (CPM, do termo em inglês *Continuous Passive*

Movement) é um tipo de terapia indicada por fisioterapeutas e ortopedistas para pessoas que sofreram lesões musculares ou em articulações. Esta técnica foi proposta originalmente por Robert Salter (KISNER; COLBY, 2009) e consiste de um dispositivo mecânico conhecido como máquina de COM que realiza movimentos pré-programados durante um determinado intervalo de tempo. A figura abaixo mostrada é um exemplo de uma máquina de CPM comercializada. Essa máquina permite a realização de uma movimentação suave da articulação desejada (joelho neste modelo de equipamento), sem necessidade de esforço por parte do paciente (TAN, 2006).

Figura 1- Máquina de CPM



Fonte: (KINETEC, 2009)

O conceito de movimentação passiva contínua surge em contraponto ao de imobilização nos problemas ortopédicos, principalmente após a realização de cirurgias, trazendo benefícios:

- melhora a nutrição das articulações acometidas pelo estímulo à produção de líquido sinovial (induzido pelo movimento);
- prevenção da rigidez articular e muscular;
- acelera a recuperação do movimento no pós-operatório;
- maior rapidez de cura, tanto na cartilagem articular quanto nos tecidos periarticulares (tendões e ligamentos);
- manutenção de maior amplitude dos movimentos articulares;
- redução do tempo de hospitalização, da dor e do edema local;
- diminuição do ciclo de inflamação, do trauma e da perda de movimento;
- redução do risco de trombose venosa profunda após a cirurgia;

- redução do risco de osteogenia pós-traumática.

1.5.2 Movimentação ativa contínua

Segundo Juliana; Gabriel; Eloy (2006), “atualmente a eletromiografia é empregada na avaliação do alcance da doença neuromuscular ou do traumatismo, e como um instrumento cinesiológico para estudo da função muscular”. Como procedimento de avaliação, a eletromiografia clínica envolve a detecção e registro dos potenciais elétricos das fibras musculares esqueléticas.

Figura 2 - Máquina de CAM comercial



Fonte: (ARTROMOT, 2013)

Estudos que comparam as terapias CPM e CAM, afirmam que o CAM, em relação ao COM, apresenta uma melhoria na recuperação do paciente se projetada na primeira semana pós-operatória da cirurgia de artroplastia total do joelho (FRIEMERT *et.al.*, 2006). Outros estudos comparativos demonstram que a utilização do CAM deve ter prioridade em relação a Movimentação Passiva contínua, pois apresenta resultados melhores que o CPM em termos de flexibilidade, dor e qualidade de vida. (SCHULZ *et.al.*, 2018), (FRIEMERT *et.al.*, 2018).

A seguir são citados alguns dos benefícios da aplicação da Movimentação Ativa Contínua (CAM) (ARTROMOT, 2013):

- Reabsorção mais rápida de hematomas;
- Melhor circulação sanguínea e linfática;
- Profilaxia para síndromes de trombo e embolia;
- Terapia durante resistência à reabilitação;
- Acelera a coordenação e percepção sensorial após a cirurgia.

1.5.3 Eletromiografia

Os sinais mio elétricos são sinais musculares formados por variações fisiológicas na diferença de potencial eletroquímico das fibras musculares (estado de repouso e ação) e são estudados através da eletromiografia. Segundo Konrad, "é o estudo da função muscular através da investigação do sinal elétrico que os músculos emanam" (KON-RAD, 2005). A definição de Konrad nos leva a analisar a origem de sinais emanados pelos músculos. Os sinais eletromiográficos musculares são emitidos quando as fibras musculares são contraídas. Essas contrações são controladas pelo cérebro através da unidade motora.


As unidades motoras são formadas por um neurônio motor alfa e as fibras musculares que ele inerva. Isso se dá em nível de corno anterior da medula espinal. O córtex motor primário (no cérebro), por meio das *CM ce* (corticomotoneuronais) não apresenta nenhum controle córtico-espinal direto (motoneurônio alfa) e indiretamente (interneurônio inibitório, por exemplo), uma circuitaria do neurônio que motor inferior por sua vez, interfere na unidade motora (KANDEL *et.al.*, 2000).

- Unidade muscular: Conjunto de fibras inervadas por um único motoneurônio alfa.
- Unidade motora: É a unidade muscular com o motoneurônio alfa que a inerva.
- Placa Motora: Conexão entre o motoneurônio alfa e uma fibra muscular alvo.

Nesse contexto, estudos em áreas como reabilitação, ergonomia ou esportes, podem contar com a eletromiografia, uma ferramenta muito poderosa na avaliação do estímulo muscular das pessoas no que diz respeito da sua interação com o meio ambiente. Desse modo, a eletromiografia abre uma série de possibilidades para pesquisas envolvendo doenças ocupacionais, design de produtos, biomecânica e a reabilitação pós-cirúrgica.

O fenômeno que envolve o controle dos neurônios na excitabilidade das fibras musculares é explicado através do modelo das membranas semipermeáveis. Esse modelo explica como trocas dos íons de sódio (Na^+) e potássio (K^+) na membrana celular através do mecanismo chamado de bomba sódio-potássio. Como é possível observar na figura 7 íons ocorrem até um certo ponto, ervilhas esses íons deslocam-se em conformidade com o estado do gradiente eletroquímico, gerando despolarização e repolarização. Quando esse fenômeno o potencial elétrico é elevado de $-80V$ (condição de repouso) a $30V$ (despolarização) (KONRAD, 2005).

Figura 3 – Ciclo de despolarização e repolarização da membrana muscular



Fonte: (KONRAD, 2005)


A combinação desse processo por todas as unidades motoras (UM) forma o sinal eletromiográfico muscular. Assim, um EMG (t) pode ser representado pelo somatório do potencial elétrico de unidades motoras, mas uma parcela de ruídos η (). Esses ruídos podem ser de origem biológica assim como do equipamento de coleta dos dados. Desse modo, o sinal de uma contração muscular capturado por um eletrodo é matematicamente representado pela equação 1 (YOUSEFI; HAMILTON-WRIGHT, 2014).

$$EMG(t) = \sum_{m=1}^n UM(t) + n(t)$$

1.5.4 Decomposição de um sinal eletromiográfico

Uma análise da origem do sinal eletromiográfico muscular, por meio de eletrodos (de superfície, por exemplo) permite captar e essas variações de potencial elétrico. Tendo em vista o fato de o sinal elétrico muscular ser muito pequeno e bastante suscetível a ruídos, este sinal é condicionado (filtrado e amplificado) por um equipamento chamado eletro-miógrafo, antes de ser armazenado e processado em um computador digital (KONRAD, 2005).

Figura 4 – Processo simplificado de aquisição e caracterização de um EMG



Fonte: (KONRAD, 2005).

A figura acima mostra um esquema de como são coletadas, processadas e extraídas informações, por exemplo, da fadiga muscular, de um sinal eletromiográfico. O esquema é basicamente dividido em três etapas:

- Posicionamento dos eletrodos nos músculos desejados e o condicionamento do sinal (eletromiógrafo) para ser processado num computador;
- Análise do espectro em frequência do sinal, por meio de técnicas de processamento digital de sinais;
- Análise da relação da frequência de média do sinal com uma fadiga muscular.

Como converter, como técnicas de processamento digital de sinais estão presentes na análise do EMG. Uma das mais usadas na FFT (*Fast Fourier Transform*). Após realização da FFT é possível analisar o comportamento do EMG no domínio de frequência e, por fim, encontrar padrões de fadiga de forma não invasiva. Um dos padrões de busca é o declínio da frequência do sinal, conforme o exercício progride. Por exemplo, em uma série de exercícios de hipertrofia muscular (levantamento de peso), essa série pode ser dividida em três faixas: início, meio e fim.

Como pode ser observado na figura acima na segunda etapa da série, uma fadiga muscular (fisiologicamente esperada) do indivíduo conforme o exercício progride no tempo é percebida no domínio frequência. Dessa maneira, na terceira etapa é possível construir um gráfico que envolve as frequências medias de cada etapa do exercício, e conseqüentemente, possivelmente notar que uma tendência decrescente existe (KONRAD, 2005).

Além da análise em frequência, no processo de caracterização de sinais eletromiográficos, existem outras informações disponíveis no mesmo, um sumário de outras características mais buscadas pode ser observado a seguir (YOUSEFI; HAMILTON-WRIGHT, 2014):

- Energia do sinal e Amplitude;
- Duração do pico da amplitude máxima;
- Duração de início e fim da contração;
- Taxas de disparo das contrações.

1.5.5 Caracterização de sinais de EMG baseada em IA

A primeira ideia concreta de inteligência artificial (IA) surgiu na década de 50, quando se pensava na criação de máquinas que pudessem pensar de forma inteligente, tendo como objetivo imitar ou até mesmo superar o pensamento humano. Dentre as várias definições de IA, segundo George F. Luger, "inteligência artificial (IA) pode ser definida como o ramo da ciência da ciência que se ocupa da automação do comportamento inteligente" (LUGER, 2004). Com base nessa definição, observa-se que a inteligência artificial é fundada, estudada e aprofundada dentro da ciência, pois é neste campo que as aplicações práticas da IA são viabilizadas por meio de linguagens e técnicas de programação, assim como algoritmos (LUGER, 2004).

Anos depois, como uma parte que integra o conceito de inteligência surge artificial o conceito de *machine learning*, ou aprendizado de máquina, em que basicamente a ideia era usar o computador a aprender por si próprio utilizando dados disponíveis sobre o problema. Logo de início, o *machine learning* entende sua importância para as práticas de IA, pois a skill de aprender é um requisito primordial aos sistemas que se dizem inteligentes (LUGER, 2004).

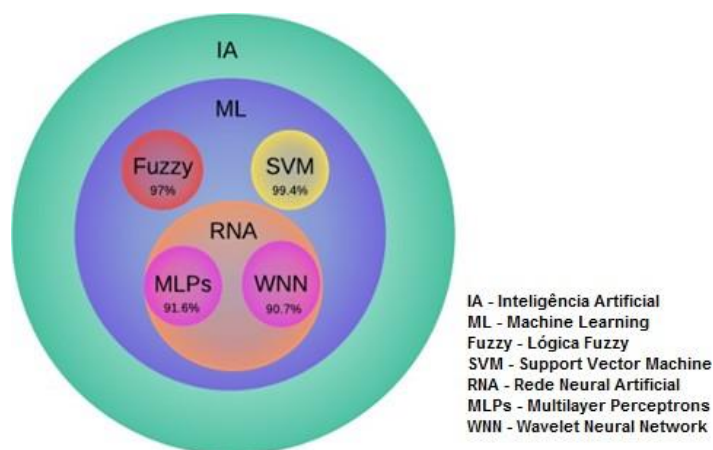
Do ponto de vista de Eethem Alpaydin, "software de aprendizagem de máquina para otimizar o critério de desempenho utilizando dados passados ou exemplos" (ALPAYDIN, 2009). Essa definição mais prática e objetivo, nos mostra que o aprendizado de máquina é utilizado em casos nos quais não se pode diretamente escrever um algoritmo para um determinado problema, sendo necessária experiência ou inserção de dados sobre o mesmo.

Desse modo, o aprendizado de máquina é necessário, quando as pessoas não têm

experiência suficiente para modelar o problema devido a sua complexidade, como por exemplo no reconhecimento de imagens, na distinção de sotaques em discursos ou ainda particularidades em caligrafias. Por outro lado, o aprendizado de máquina pode ser útil também nos casos em que temos vários algoritmos que solucionam o problema, mas sequer buscar o otimizado possível (ALPAYDIN, 2009).

Atualmente, métodos que "aprendem com os dados", tem estado cada vez mais apresentam em todas as áreas do conhecimento humano, entre elas na engenharia biomédica e na identificação de padrões de EMG, dentre outros. Neste contexto, o processo de informações de um EMG requer a utilização de ferramentas que o *machine learning* oferece. A figura 5, mostra algumas das técnicas, de modo geral, mais adotadas (com suas únicas acurácias) na caracterização de sinais de EMG muscular (SUBASI, 2013; YOUSEFI; HAMILTON-WRIGHT, 2014).

Figura 5 - Técnicas do Machine Learning mais utilizados na classificação de EMGs



Fonte: (SUBASI, 2013)

1.5.6 Redes neurais artificiais

Os algoritmos de redes neurais artificiais (RNA), são outra ferramenta do *machine learning*, dentre as várias que são utilizadas para "usar o computador". Na medicina contemporânea, esses algoritmos são usados como ferramentas de auxílio aos profissionais da área. Uma RNA acelera o processo de diagnóstico de uma doença neuromuscular de um paciente, por meio da identificação de padrões de sinais eletromiográficos. As RNAs são bastante utilizadas na medicina devido à sua habilidade de aprender com exemplos, tolerância a incertezas e imprecisões, que surgem na interpretação dos sinais biológicos, como é o caso de EMGs. (SUBASI, 2013; ALPAYDIN, 2009; YOUSEFI; HAMILTON- WRIGHT, 2014).

Como o foco deste trabalho é a utilização de uma RNA para a identificação dos padrões eletromiográficos, uma definição sobre redes neurais é necessária. Portanto, Symon

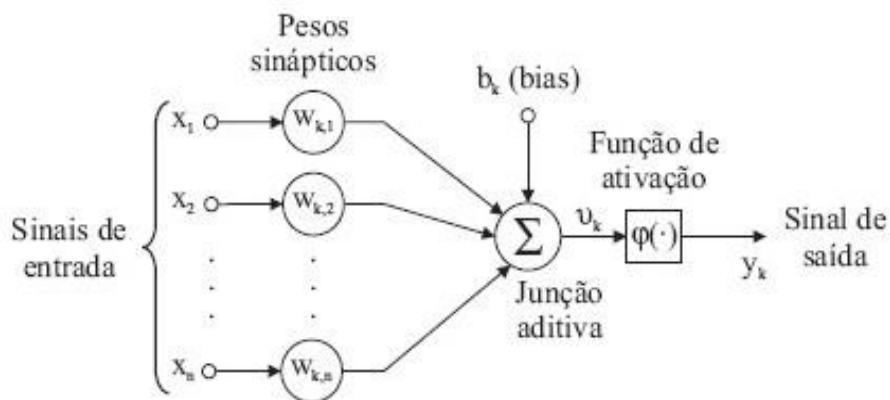
Haykin define uma rede neural como sendo, " um processador maciçamente paralelamente distribuído, constituído de unidades de processamento simples, que têm uma propensão de armazenar o conhecimento experimental e torná-lo disponível para o uso "(HAYKIN et al., 2009). Desse modo, podemos concluir que uma rede neural artificial se assemelha ao cérebro, basicamente em dois aspectos:

1. O conhecimento é adquirido pela rede neural por meio de um processo de aprendizagem;
2. A força da conexão entre os neurônios (pesos sinápticos) é um responsável pelo armazenamento do conhecimento;

1.5.7 Perceptrons Multicamadas

Em meio aos vários arranjos possíveis para as redes neurais, um muito usual e bastante consistente na identificação de padrões eletrográficos é o MLP (perceptron multilayer) também conhecido como *feedfad*. Outras arquiteturas bem usuais são: probabilísticas de RNAs, recorrentes de RNAs (rede neural recorrente), dentre outras. Segundo Yousefi *et al.* (2014), as MLPs treinadas com o algoritmo supervisionado *backpropagation* (BP) apresentam um desempenho na identificação de padrões em EMGs na faixa de 90%. Além disso, RNAs treinadas com o BP tendem a ser mais consistentes em comparação com outros tipos de treinamento (YOUSEFI; HAMILTON-WRIGHT, 2014; HAYKIN *et al.*, 2009).

Figura 6 – Modelo de um neurônio artificial



Fonte: (HAYKIN *et al.*, 2009)


O modelo de neurônio artificial apresentado na figura 10 é construído com base nas

definições de aparência na seção anterior (1.5.6) e, assim como o neurônio humano, que é um sistema não-linear. Esse modelo de neurônio serve de base para uma construção das diferentes arquiteturas locais (HAYKIN *et al.*, 2009).

Os sinais de entrada dos neurônios são ponderados pelos pesos sinápticos W , (podendo esses valores serem tanto positivos como negativos), sendo o índice do neurônio na camada escondida (ou na camada de saída) (i -ésimo neurônio) e o índice da entrada de entrada (j -ésima entrada). Após os sinais passarem pelos pesos sinápticos, eles são somados na junção aditiva formando o sinal v . Nesta junção aditiva pode-se ainda adicionar o valor b que é conhecido como viés e tem a função de aumentar ou diminuir o valor do sinal v , antes deste passar pela função de ativação. O sinal de saída é finalmente publicado após a passagem pela função de ativação φ , que limita em amplitude (saturação) o sinal a um valor finito, geralmente normalizado com valores entre $[0,1]$ ou $[-1,1]$ (HAYKIN *et al.*, 2009).

O modelo de neurônio artificial visto na figura 10, como cenário anteriormente, pode ser estruturado de diversas formas; contudo, é necessário ter em mente que essa estrutura está diretamente relacionada com o modo de aprendizagem que será utilizado posteriormente no treinamento da RNA. Um exemplo de uma MLP com uma camada oculta pode ser observada na figura 7. Nesse modelo de rede neural, os neurônios são conectados em separados, sendo elas respectivamente: entrada, oculta e de saída (HAYKIN *et al.*, 2009).

Figura 7 – Rede neural com camadas ocultas



Fonte: (HAYKIN *et al.*, 2009)

No processo de criação de uma rede neural, um dos parâmetros mais importante a serem observados é o número de neurônios na camada escondida. Contudo, esse parâmetro é difícil de estabelecer e, geralmente, escolhido de forma empírica ou por tentativa e erro, de uma forma que atenda aos requisitos desejáveis do projeto. A equação 2, mostra uma das fórmulas utilizadas como base para a escolha do número de neurônios da camada escondida de uma RNA, onde, N_n representa o número de neurônios desejados na camada escondida, n é o número de neurônios da camada escondida neurônios da camada de saída, e θ uma constante arbitrária de ajuste (CUI *et al.*, 2017).

$$N_n = \sqrt{in + out} + \theta$$

1.5.8 Sistema de controle

De modo geral, controlar um processo significa manter como variáveis controláveis da planta dentro de seus limites de operação. Dessa forma, o objetivo de um driver é atuar nas variáveis do processo (planta), de forma a atingir ou manter determinados requisitos (TORGA, 2018). Como cada processo possui características diferentes, o modelo matemático do processo muda, conseqüentemente como variáveis a serem controladas se alteram. No caso de uma máquina de CPM / CAM, o objetivo principal é controlar a posição (deslocamentos lineares / angulares) de forma robusta. Portanto, uma avaliação da estabilidade se faz necessária durante o projeto do sistema de controle. Neste trabalho, uma análise de estabilidade e uma representação do modelo do processo, bem como o projeto do sistema de controle, são realizados no domínio de Laplace (domínio frequência), representados pela variável.

1.5.9 Modelagem matemática de uma máquina de CPM / CAM


A máquina de CPM é um tipo de manipulador eletromecânico com tais graus de liberdade, sendo eles translações nos eixos X e Y, como pode ser visto no esquema da figura 12. Um fim de modelar esse sistema é necessário considerar não só o mecanismo em si, mas também sua interação com o corpo humano (HOGAN, 1985).

Essa interação ocorre da seguinte forma: o paciente, ao colocar o membro na plataforma e realizar esforço contra o suporte para o pé (pedal), exerce uma força (carga) que movimenta o mecanismo da plataforma. Essa força é medida por meio da eletromiografia e serve como sinal de realimentação (*feedback*) de modo que o sistema realiza uma força oposta, um fim de realizar o movimento ativo assistido (CAM).

Durante o exercício CAM, o paciente tem uma impressão de estar pressionada uma

mola com o pé. Essa sensação de "mola virtual" oferece mais ou menos resistência ao paciente, conforme definido no sistema de controle (HO; CHEN, 2009).

Figura 8 – Sistema de impedância mecânica-interação máquina de CPM/CAM-paciente




Fonte: (HO; CHEN, 2006; KINETEC, 2009)

Assim, uma interação entre a força realizada pelo paciente e o mecanismo CPM pode ser aproximada segundo o modelo genérico de "controle de impedância" de Hogan, em conformidade com a equação 4.3 (HOGAN, 1985), sendo F a força aplicada pelo usuário ao mecanismo, que produz um deslocamento linear do sistema, representado por x . A massa do sistema corresponde a M , enquanto b corresponde ao fator de amortecimento, K é a constante da mola e $cg(\dot{x})$ a fricção não-linear de Coulomb (HO; CHEN, 2008), a aceleração, velocidade e posição são respectivamente, \ddot{x} , \dot{x} , e x .

$$M\ddot{x} + b\dot{x} + kx + csgn(\dot{x}) = F \quad (3)$$

Desconsiderando o atrito $cg(\dot{x})$ da equação 3, o modelo da máquina de CPM é resumido como um sistema de controle da segunda ordem do tipo massa-mola-amortecedor (mbk), conforme figura 9 (a), bem como seu respectivo diagrama de blocos (b) (NISE, 2007).

Figura 9 – Modelo de impedância de segunda ordem



(a) Sistema m-b-k; (b) Diagrama de blocos.

Fonte: (NISE, 2007)

Os coeficientes m-b-k do modelo de segunda ordem da máquina de CPM (eq.4.3), representado por $G()$ podem então ser buscados da equação característica 4 onde: ζ representa o fator de amortecimento e ω_2 é a frequência de oscilação natural do sistema (NISE, 2007).

$$G_P = \frac{1}{Ms^2 + 2bs + k} = G_P(s) = \frac{w^2 n}{s^2 + 2Wn^s + wn^2} \quad (4)$$

O modelo de referência da máquina de CPM / CAM para o sistema de controle deve ser o mais próximo do real, a fim de evitar desconforto ao paciente no momento da execução do exercício. Portanto, onde modelo deve evitar oscilações, estar sobre taxa de velocidade e deslocamento máximo da pista do equipamento. (HO; CHEN, 2009).

1.5.1 Captação do sinal

Eletrodo

A função do eletrodo é monitorar o sinal eletromiográfico convertendo a corrente iônica bioelétrica a uma corrente formada por elétrons. Esta conversão acontece no eletrodo e na interface onde a mudança de íons para elétrons ocorrem livremente. A principal condição de qualquer eletrodo utilizado para análise eletromiografia é que seja um sistema reversível e não polarizado. Tanto as reações de oxidação quanto as reduções devem ocorrer com a mesma facilidade ou então os eletrodos tornam-se polarizados durante o uso e inibem o fluxo de corrente bidirecional. Materiais como ouro e alumínio são facilmente polarizados e exibem altos potenciais de eletrodos, o coeficiente de temperatura do material também é um fator importante, pois alguns materiais mudam suas propriedades com pequenas variações na temperatura. “O ideal é que os eletrodos sejam feitos do mesmo material e não possuam diferença de potencial entre eles” (SODERBERG; COOK, 1984). Segundo Hermens et al. (2000), “os materiais mais utilizados são prata/cloreto de prata (Ag/AgCl) e prata (Ag)”.

Os eletrodos que capturam os potenciais elétricos do músculo em contração podem ser de dois tipos:

Eletrodos de Superfície

São pequenos discos metálicos, mais comumente feitos de prata/cloreto de prata, colocados sobre a pele. São muito mais convenientes para os clínicos, mais aceitáveis pelos

pacientes e produzem menos movimentos, método não invasivo e de fácil execução. Usado para músculos superficiais. Faz-se necessária a preparação da pele, que pode ser a lavagem ou fricção com álcool, para remoção das células epiteliais mortas. Aplica-se gel de eletrodo, para que seja facilitada a condução dos potenciais elétricos. O eletrodo deve ser firmemente aderido à pele, com fitas adesivas, para evitar interferências ao serem realizados os movimentos (SULLIVAN, 2000; RODRIGUEZ-ANEZ, 2004; TORRIANI; CYRILLA, 2003; BASANTE; SPROESSER; PAIVA, 1997; TURCIO; GARCIA; DEROGIS; ZUIM, 2002).

Eletrodos de profundidade

Os eletrodos são colocados no interior do músculo, utilizando-se dois filamentos de arame de pequeno calibre, revestidos, que são introduzidos através de uma agulha hipodérmica. Pouco utilizado por ser um método invasivo (SULLIVAN, 2000; RODRIGUEZ-ANEZ, 2004; TORRIANI; CYRILLA, 2003; TURCIO; GARCIA; LAAT; KAMIYAMA, 2004).

Os eletrodos ainda podem ser classificados como:

Monopolar

“Um eletrodo é colocado sobre o feixe muscular de interesse e o outro eletrodo é colocado num ponto não afetado pela atividade do feixe muscular de interesse, mede-se então a diferença de potencial entre esses dois pontos” (RODRIGUEZ-ANEZ, 2004).

Bipolar

Dois eletrodos sobre a região que se deseja estudar e o terceiro eletrodo chamado terra é colocado num local não afetado pela atividade da região de interesse. Mede-se agora a diferença de potencial elétrico entre os dois eletrodos que estão sobre a região de interesse, tomando-se como referência o eletrodo terra (FERRARIO; SFORZA; TARTAGILA; DELLAVIA, 2002; BASANTE; SPROESSER; Paiva, 1997 e RODRIGUEZ-ANEZ, 2004).

1.6 OBJETIVOS

O objetivo deste trabalho é realizar uma análise bibliométrica para explorar e avaliar os dados coletados na revisão da literatura. O princípio da bibliometria é analisar a atividade científica ou técnica por meio de estudos quantitativos de publicações. Além disso, os indicadores quantitativos, além de apoiarem a compreensão da dinâmica da ciência e da tecnologia, funcionam também como ferramentas de planejamento e tomada de decisão.

1.7 ESTRUTURA DA DISSERTAÇÃO

Este trabalho está organizado de acordo com os seguintes capítulos:

Capítulo 1: Apresentação do estudo sobre diagnóstico clínico, Inteligência Artificial, Inteligência Artificial na medicina, eletromiografia para diagnóstico, objetivo do trabalho e revisão de literatura.

Capítulo 2: Materiais e Método;

Capítulo 3: Resultado;

Capítulo 4: Discussão;

Capítulo 5: Considerações finais.

2 MATERIAIS E MÉTODO

Nenhum trabalho científico pode ser feito sem recorrer a certos métodos e técnicas para realizar pesquisas. Segundo Prodanov & Freitas (2013), “este artigo é classificado, do ponto de vista de sua natureza, como pesquisa básica, com o intuito de gerar conhecimento para o avanço da ciência, sem pretendida aplicação prática”. Quanto aos seus objetivos, é descritivo-compartmental, descritivo para procurar descrever os vários aspectos da inteligência artificial, nomeadamente a sua natureza, as suas características, as suas vantagens e as suas aplicações e comparativo para comparar a evolução da IA em 1980 a 2021, quando é associado ao medicamento (EMG).

Segundo Petticrew & Roberts (2008), “a abordagem é uma forma de contribuir para o que funciona e o que não funciona e identifica as pesquisas relevantes foram feitas ou não e onde novos estudos são importantes”. Higgins & Green (2011), “para atingir os objetivos sugeridos, a coleta de dados é feita por meio de técnicas de revisão bibliométrica, abordagem que nos permitiu reunir todas as evidências práticas, com base nos critérios de elegibilidade estabelecidos (de 1980 a 2021), a fim de responder a uma pergunta de pesquisa específica”.

A coleta dos dados ocorreu no período de março a junho de 2021. Para selecionar a amostra foram adotados os seguintes critérios de inclusão: publicações na modalidade de artigo, com texto completo disponíveis gratuitamente, que abordassem como temática do presente estudo, publicados no período de 1995 a 2021, conhecidos em língua inglesa. Foram excluídas publicações como: teses, manuais, dissertações, livros. O segundo critério utilizado para filtragem foi a leitura dos resumos dos artigos, onde 38 artigos foram excluídos por não apresentarem o tema proposto e sim, apenas, palavras-chave em comum, totalizando 40 artigos selecionados. Dos 40 artigos selecionados para leitura completa, foram selecionados 30 artigos para esta revisão bibliométrica. Importante ressaltar que as buscas, quando limitadas nos termos “AI” e “EMG”, apresentam um número elevado de artigos disponíveis nos bancos de dados, essa condição não se repete quando adicionado o termo “diagnóstico

clínico”.

O quantitativo de documentos que atendeu aos critérios de inclusão acima referidos compôs a amostra inicial do estudo com 30 artigos, destes 26 no Scopus, 3 no IEEE Xplore e 1 no Pubmed, desconsiderando as referências que se repetiam e não interessavam ao objetivo do estudo. Para estruturar os dados que foram tirados dos artigos, usamos uma planilha elaborada no *Excel for Windows*. O mesmo foi preenchido com as seguintes informações: Título do artigo, autores, ano de publicação, fontes da publicação, número de citações por ano, palavras-chaves, laboratórios, ferramentas do diagnóstico com IA, eficiência do diagnóstico.

O preenchimento dessa planilha foi realizado após a leitura dos artigos na íntegra, formando um banco de dados extraídos dos 30 artigos. Em seguida, os estudos foram avaliados por meio de aplicação de análise crítica dos mesmos. Nessa etapa, estudos foram excluídos da amostra. Os resultados dessa análise foram discutidos à luz do conhecimento teórico, bem como identificados as conclusões e implicações resultantes da revisão bibliométrica. Outrossim, este estudo apresenta sugestões pertinentes para futuras pesquisas direcionadas para a melhoria da assistência da inteligência artificial na medicina, quando for aplicado na eletromiografia.

Na formulação dos dados foram usados estudos realizados entre os anos de 1995 a 2021. As buscas se realizaram entre os meses de março a junho/ 2021, através dos bancos de dados, como: IEEE Xplore, PubMed e Scopus usando a opção mais ampla disponível em cada uma. Foram utilizadas na pesquisa as palavras-chaves seguintes: *diagnosis*, *artificial intelligence and machine learning*. Foram utilizados os operadores de pesquisa ou booleanos, usados para relacionar termos ou palavras em uma expressão de pesquisa. Combina dois ou mais assuntos, nomes ou palavras, de um ou mais campos de busca. Os operadores de pesquisa utilizados na maioria das fontes de informação são: AND/OR/AND NOT. Tanto no método de pesquisa integrado quanto por palavras o operador de pesquisa considerado automaticamente é o AND, portanto não é necessário digitá-lo entre as palavras (CARONI, 2003).

Exemplo1: *diagnosis AND artificial intelligence*

<i>diagnosis AND artificial intelligence</i>		
(156)		(300)
<i>diagnosis</i>	<i>n</i>	<i>artificial intelligence</i>
= (40)		

“Serão recuperados documentos que têm as duas palavras decorrendo simultaneamente no(s) campo(s) para onde a pesquisa estiver sendo orientada” (Bruno Caroni, 2003).

OR = União

União - usado para somar palavras/termos/nomes.

Exemplo 2: *Diagnosis OR Artificial intelligence*

<i>diagnosis OR artificial</i>		
<i>intelligence</i>		
<i>(156)</i>		<i>(300)</i>
<i>diagnosis</i>	U	<i>artificial</i>
<i>intelligence</i>		
$156+300-40 = 416$		

Em conformidade com Caroni (2003), serão recuperados documentos que têm uma e/ou outra das palavras no(s) campo(s) para onde a pesquisa estiver sendo direcionada. Observe que é eliminada a duplicidade de artigos que contêm as duas palavras (40).

AND NOT

Exclusão - usado para excluir palavras/termos.

Exemplo 3: *Eclampsia AND NOT Hipertensão*

diagnosis

Intelligence artificial

<i>diagnosis OR artificial intelligence</i>	
<i>(156)</i>	<i>(300)</i>
$156-40 = 116$	

Serão recuperados documentos que incluem a primeira palavra, excluindo documentos que contenham a segunda palavra no(s) campo(s) para onde a pesquisa estiver sendo direcionada (representado pela área listada na figura).

Os parênteses são utilizados quando queremos usar mais de um operador que vão nos facilitar a delimitar a ação de cada operador.

Exemplo: para recuperar registros sobre hipertensões relacionadas com eclâmpsia ou pré-eclâmpsia, devemos usar a expressão.

Hipertensão *AND* (eclâmpsia *OR* pré-eclâmpsia).

Sem o uso dos parênteses, o sistema recuperaria registros sobre hipertensão e eclâmpsia, mais os registros sobre pré-eclâmpsia.

Importante:

- Usando o operador *AND NOT* a ordem altera o resultado:

Diagnosis AND NOT artificial intelligence

é diferente de *artificial intelligence AND NOT Diagnosis*

- O uso de mais de um operador em uma mesma expressão de pesquisa pode ter o resultado alterado de acordo com a ordem das palavras/termos.

No exemplo *artificial intelligence AND diagnosis OR pre- diagnosis*

“Serão buscados documentos que contenham a palavra *artificial intelligence e diagnosis*, mais os documentos que contenham a palavra *pré-diagnosis* sem necessariamente associar com a palavra hipertensão” (BRUNO CARONI, 2003).

A ordem correta é:

(diagnosis OR pre- diagnosis) AND artificial intelligence.

Assim, serão buscados primeiramente a soma de documentos com as palavras *diagnosis ou pre- diagnosis* e depois feita a relação com a palavra *artificial intelligence*.

Segundo Bruno Caroni (2003),

(...) existem condições que devem ser observadas na pesquisa por palavras:

- O primeiro passo importante é selecionar as palavras mais significativas do que estamos buscando para compor a estratégia da pesquisa, excluindo os artigos, preposições, verbos etc. Identificar as palavras corretas é a chave para recuperar de forma eficiente a informação que está sendo buscada.
- Não se preocupe com letras maiúsculas ou minúsculas. Toda letra, independentemente de como se digita, será compreendida como letra minúscula. Acentuação também não faz nenhuma diferença.
- Não é necessário incluir o operador booleano *AND* entre as palavras digitadas na caixa de busca, uma vez que o sistema assume este operador automaticamente.
- O idioma das palavras pode ser português, inglês e/ou espanhol, uma vez que temos na BVS referências de documentos nestes 3 idiomas. Mas o idioma das palavras, SIM, modifica o resultado da pesquisa.
- É possível trocar uma palavra usando o recurso representado pelo sinal \$. Digitando \$ imediatamente depois da raiz de uma palavra podemos recuperar todas as variações da palavra na pesquisa.

Tabela 1- Estruturação das palavras chaves os respectivos resultados.

Base de Dados	Relatores de busca	Resultado encontrado	Filtrado periódico	Qtde após filtragem
SCOPUS	("EMG" OR "electromyography") AND ("diagnostic" OR "diagnosis") AND ("clinical") AND ("artificial intelligence" OR "machine learning" OR "deep learning")	31	1995/2021	26
PUBMED	((EMG[Title/Abstract]) R (electromyography[Title/Abstract])) AND ((diagnostic[Title/Abstract]) R (diagnosis[Title/Abstract])) AND D (clinical[Title/Abstract]) AND (("artificial intelligence"[Title/Abstract]) OR ("machine learning"[Title/Abstract]) OR ("deep learning"[Title/Abstract]))	14	1995/2021	1
IEEE XPLORE	((("Document Title":electromyography OR "Abstract":electromyography) R ("Document Title":EMG OR "Abstract":EMG)) AND ((("Document Title":diagnostic OR "Abstract": diagnostic) OR ("Document Title":diagnosis OR "Abstract": diagnosis)) AND ((("Document Title": "artificial intelligence" OR "Abstract": "artificial intelligence) OR ("Document Title": "machine learning" OR "Abstract": "machine learning") OR ("Document Title": "artificial neural network" OR "Abstract": "artificial neural network"))))	33	1995/2021	3

Fonte: O Autor

Critérios de inclusão

- Artigos publicados no período de 1975 a 2021;
- Artigo que correspondia com as minhas palavras-chaves.

Critérios de exclusão

- Artigo que não contemplava o objetivo da pesquisa;
- Trabalho com dupla indexação;
- Foram excluídas as conferências e livros;
- Estudos teóricos ou que focavam assuntos não relacionados com a palavras-

chaves que foi utilizado.

A partir dos critérios de inclusão e exclusão, dos 78 artigos localizados inicialmente, foram excluídos 38 artigos que não contemplava o objetivo da pesquisa. Observamos um aumento na produção científica na última década, o que justifica o presente trabalho. Foram excluídos, ainda, alguns artigos, que estudavam a inteligência artificial na visão de outras áreas, considerando apenas os artigos que se trata da eletromiografia utilizando a inteligência artificial. A Figura 1 mostra os resultados dos artigos selecionados por ano, no período de 1995 a 2021. Desta maneira, constata-se uma tendência de aumento das publicações.

Figura 10 – Frequência dos artigos selecionados por ano.



2.1 ESCOLHA DE PALAVRAS-CHAVE

Dada a diversidade de termos utilizados para qualificar “eletromiografia”, optamos por combinar seis palavras-chave em inglês para ter cobertura internacional da produção científica sobre essa noção: *Electromyography; Diagnosis; Diagnosis; Machine Learning; Clinical; Deep; Artificial Intelligence* dependendo de cada base de dados como indica a tabela 1.

Segundo Aznar & Mareschal (2012), as palavras-chave em inglês foram então adaptadas para limitar as perdas de itens. Para evitar a não contagem de um artigo, cuja referência usa um termo ligeiramente diferente. Em seguida, combinamos as seis palavras-chave usando um operador booleano combinando como mostra a tabela 1. A solicitação relacionada ao intervalo de tempo: ano de 1995 a ano 2021 incluiu.

Por fim, iniciamos a pesquisa e armazenamos as informações no *software* de gerenciamento de banco de dados bibliográficos.

2.2 ESCOLHAS DE BANCO DE DADOS

Escolhemos este maior banco de dados de citações e resumos da revisão revisada por pares: periódicos científicos, artigos. “Scopus oferece uma visão abrangente dos avanços da pesquisa global em ciência, tecnologia, medicina, ciências sociais e artes e humanidades, juntamente com ferramentas inteligentes projetadas para rastrear, analisar e visualizar a pesquisa” (SAIF *et.al.*, 2019).

Bases de dados literários são comumente usados para avaliar publicações em um assunto, disciplina, país ou região do mundo, uma prática conhecida como análise bibliométrica. O protocolo atual detalha como usar os bancos de dados PubMed, Scopus e IEEE para realizar análises bibliométricas.

Bancos de dados literários, ou seja, PubMed, Scopus e Web of Science diferem em termos de cobertura, foco e ferramenta que fornecem. O PubMed concentra-se principalmente nas ciências da vida e disciplinas biomédicas, enquanto o Scopus e o Web of Science são multidisciplinares. O protocolo descrito neste estudo foi utilizado para busca de publicações de autores jordanianos nos anos de 2013-2017. Neste protocolo, é explicado em detalhes como usar cada banco de dados para realizar este tipo de pesquisa. Uma pesquisa no Scopus resultou no maior número de documentos (11.444 documentos), seguida por uma pesquisa na web de ciências (10.943 documentos). O PubMed obteve um número menor de documentos devido ao seu escopo e cobertura mais restritos (4.363 documentos). Os resultados também mostram uma tendência a cada ano: (1) o número de publicações, (2) as disciplinas com mais publicações, (3) os países de colaboração e (4) o número de publicações de acesso aberto. Em contraste, o PubMed tem um serviço sofisticado de otimização de palavras-chave (ou seja, Medical Subject Heading ou MeSH), enquanto o Scopus e o Web of Science fornecem ferramentas de análise de pesquisa que podem produzir números representativos. “Por fim, as características de cada base de dados são explicadas em detalhes e várias pistas que podem ser extraídas a partir dos resultados da pesquisa são fornecidas. Este estudo fornece uma base para o uso de bancos de dados de literatura para análises bibliométricas” (SAIT *et.al.*, 2019).

3 RESULTADOS

Foram examinados 30 artigos, todos publicados em inglês. Os artigos foram publicados em diferentes periódicos sendo: *204 IEEE transactions on information technology in biomedicine*, *the iioab jornal*, *Technology and Health Care 21*, *Computers in Biology and Medicine*, *Healthcare Informatics Research*, *BioMed Research International*, *Journal of Neuroscience Methods*, *Computing in Biology and Medicine*, *Journal of Science*, *Neural*

Processing Letters, IEEE Transaction on Biomedical Engineering, Elsevier Ltd. Medical and Physics Engineering, Diagnosis, Elsevier Ltd Biomedical Signal Processing and Control 1, IEEE Journal of Biomedical and Health Informatics, IEEE Transactions on Neural Systems and Rehabilitation Engineering, IEEE Transactions on affective Computing, npj Digital Medicine, Biopotential pain pattern via machine learning, IEEE Transactions on Neural Networks, IEEE Transactions on Biomédica Engineering, IEEE Transactions on Instrumentation and Measurement, BMC Neuroscience, IEEE Access, Frontiers in Public Health.

Tabela 2 – Histórico das publicações de cada autor

Número Citações	Autores	Laboratórios	Número Citações/ Ano	Países
128	<i>Hassan Ghasemzadeh, Roozbeh Jafari, e Balakrishnan Prabhakaran</i>	<i>Department of Computer Science, University of Texas at Dallas, Dallas, USA.</i>	<i>12/2011, 13/2013, 14/2015, 10/2014, 11/2012, 3/2010, 16/2017, 12/2018, 10/2016</i>	<i>USA.</i>
2	<i>Suja Priyadharsini, Bala Sonia , Dejey</i>	<i>Sugam Health Centre, Tirunelveli, Tamil Nadu</i>	<i>1/2016 , 1/2019</i>	<i>India</i>
8	<i>Abdulnasir Hossen</i>	<i>Department of Neurology, University of Kiel, Germany</i>	<i>1/2014, 2/2015, 1/2017, 1/2018, 3/2020</i>	<i>Germany</i>
403	<i>Abdulhamit Subasi</i>	<i>Department of Neurology, University of Gaziantep (INGLÊS)</i>	<i>1/2019, 33/2015, 49/2016, 4/2013, 32/2014, 57/2020, 52/2018, 48/2017,</i>	<i>Bósnia and Herzegovina</i>

 Continuação...

1	Sangwoo Nam, Min Kyun Sohn, Hyun Ah Kim , Hyoun-Joong Kong Il-Young Jung	medical Center	1/2021		Korea
15	Emine yaman e Abdulhamit subasi	Department of Neurology at Gaziantep University.	5/2020, 10/2021		Saudi Arabia
10	Anders Vinther Olsen, Jensstephansen, Eileen Leary, Poul Peppard, Hong Sheungshul, Poul Jorgen Jennum, Helge Sorensen, Emmanuel Mignot.	Orphan Medical, now Jazz Pharmaceuticals .	2/2018, 1/2019, 5/2020,2/2021		USA
75	Abdulhamit Subasi	Department of Neurology at Gaziantep University.			Bosnia and Herzegovina

 Continuação...

3	Rukiye Uzun, Okan Erkaymaz, Irem Senyer Yapici	Department of Electrical and Electronic Engineering e Department of Computer Engineering	1/2019, 2/2021	Turkey
2	Luca Parisi e Narrendar Ravichandar	University of Auckland Rehabilitative Technologies Association (UARTA).	1/2021, 1/2021	New Zelaand
41	Paulito Palmes *, Wei Tech Ang, Ferdinan Widjaja, Louis CS Tan e Wing Lok Au	I. Seah	2/2013, 5/2014, 4/2016, 6/2018, 4/2015, 1/2011, 3/2017, 3/2012, 6/2020 03/2019, 3/2021	Singapore
58	Yair Barniv , Mario Aguilar, e Erion Hasanbelliu	NI	5/2007,4/2006 1/20097/2011, 4/2010.4/20161/2012,2/2008 4/2014,4/20134/2015, 1/2019 1/2009,2/2018 4/2017,3/20202/2005,2/2008 2/2021	NI

 Continuação...

72	Changmok Choi uma , Suncheol Kwon uma , Wonil Park uma , Hae-dong Lee , Jung Kim uma .	National Instruments TM, EUA	8/2015,8/20146/2012,8/20174/2011,8/20135/2018,6/20169/2019,7/2020,3/2021	USA
58	Yair Barniv , Mario Aguilar, e Erion Hasanbelliu	N.I	5/2007, 7/2011, 4/2010.4/2016,1/ 2009,2/2008 1/2012,4 /2014 4 / 2013,2/2021 4/2006, 4/2015, 1/2019, 1/2009, 4/2017, 3/2020, 1/2018, 2/2005,	N.I
72	Changmok Choi uma , Suncheol Kwon uma , Wonil Park uma , Hae-dong Lee , Jung Kim uma .	National Instruments TM, EUA	8/2015, 8/2014, 6/2012, 8/2017, 4/2011, 8/2013, 5/2018, 6/2016, 9/2019,7/2020 3 / 2021	USA
4	Carlo ricciardi, Halldór Jónsson Jr, Deborah Jacob , Giovanni Improta , Marco, Recenti,Magn você s Kjartan Geu Slason , Giuseppe Cesarelli, Luca Esposito, Vincenzo Minutolo ,Paolo Bifulco e Paolo Gargiulo.	Iceland National Hospital	1/2020, 3/2021	Iceland

 Continuação...

205	<i>Ercan Gokgoz e Abdulhamit Subasi</i>	<i>International Burch University, Faculty of Engineering and Information Technologies,</i>	<i>7/2015, 19/2016, 50/2019, 24/2017, 28/2018, 2/2020, 1/2009, 16/2021</i>	<i>Bósnia and Herzegovina</i>
38	<i>Mostafa Shahin, Beena Ahmed e Sana Tmar-Ben Hamid, Fathima Lamana Mulaffer, Martin Glos e Thomas Penzel.</i>	<i>Plinário Sleep Center of the Charité University Hospital (INGLÊS)</i>	<i>8/2019,14/2020 5/2018, 1/2017, 8/2021,1/2015</i>	<i>Germany</i>
61	<i>Sumitra S. Nair, Robert M. French, Davy Laroche e Elizabeth Thomas</i>	<i>Sleep Laboratory at Trakya University Education and Research Hospital.</i>	<i>1/2010, 4/2021, 8/2019, 7/2018, 3/2015, 6/2016, 9/2017, 1/2013, 4/2014,2/2011, 3/2012, 9/2020</i>	<i>Turkey</i>
3	<i>E Ihan Umut e Güven Çentik</i>	<i>Sleep Laboratory at Trakya University Education and Research Hospital.</i>	<i>1/2018, 1/2020, 1/2021</i>	<i>Turkey</i>

 Continuação...

115	Omar AlZoubi, Sidney K. D'Mello e Rafael A. Calvo.	US National Science Foundation	1/2003, 1/1999, 4/2013,12/201710/2018,12/2015, 15/2019, 13/2014,7/201624/2020,1/20055/2021	Austrália (Sydney)
5	Hanna Drimalla , Tobias Scheffer , Niels Landwehr , Irina Baskow , Stefan Roepke , Behnoush Behnia e Isabel Dziobek	N.I	2/2020, 3/2021	Germany
51	Constantinos S. Pattichis and Christos N. Schizas.	Department of Computer Science at the University of Cyprus	2/2000, 4/2005, 2/2004, 3/1999, 2/2007, 1.2014, 4/42002,4/19941/2014,1/2017, 1/2004,1/2001, 2/2009, 2/1998, 2/1997, 3/2003, 1/20013,2/2010 1/2021, 3/2020, 1/2006	Nicosia, Chipre
185	Constantinos S. Pattichis, Christos N. Schizas and Lefkos T. Middleton	Cyprus Institute of Neurology and Genetics (CING)	3/2000, 9/2001, 11/1999,1/19968/1998, 7/2006, 9/2012, 3/2004, 5/2005,3/2009, 13/2007,6/20146/2015, 7/2000, 6/2003, 3/2020, 1/2009,1/2021,4/2010, 7/2008, 6/2011, 4/2002, 7/2016, 7/2017, 1/1994, 1/1995, 4/1997,15/20135/2018, 3/2010, 6/2019, 2/2011, 1/2012, 1/2005, 1/1997	Cyprus

 Continuação...

2	<i>Abdulhamit Subasi</i>	<i>N.I</i>	<i>1/2020, 1/2021</i>	<i>Saudi Arábia</i>
29	<i>Xu Zhang, Membro, Paul E. Barkhaus, William Zev Rymer e Ping Zhou</i>	<i>N.I</i>	<i>1/2014, 5/2017, 3/2016, 5/2018, 6/2020, 3/2019, 2/2021</i>	<i>China</i>
15	<i>José A Biurrun Manresa, Giang P Nguyen, Michele Curatolo, Thomas B Moeslund e Ole K Andersen</i>	<i>1Sensory-Motor Interaction Center, Department of Science and Technology of Health, Aalborg University and Computer Vision and Media Technology Laboratory</i>	<i>3/2015, 1/2016, 2/2014, 4/2020, 1/2018, 1/2019, 1/2017, 1/2021</i>	<i>USA</i>
3	<i>Hui Wen Loh, Chui Ping, Jahmunah Vicnesh, Shu Lih Oh, Oliver Faust, Arkadiusz</i>	<i>N.I</i>	<i>3/2021</i>	<i>NI</i>


Final...

1	<i>Fahmida Haque, Mamun B. I. Reaz, Muhamad E. H. Chowdhury, Fazida H.</i>	<i>National Institute of Diabetes and Digestive and Kidney Diseases (NIDDK)</i>	<i>1 / 2021</i>	<i>Qatar</i>
5	<i>Wuxiang Shi, Yurong Li, Dujian Xu, Chen Lin, Junlin Lan, Yuanbo Zhou, Qian Zhang, Baoping Xiong and Min Du</i>	<i>Natural Science Foundation of Fujian Province</i>	<i>5/2021</i>	<i>China</i>

Fonte: O Autor.

No decorrer de um período de 1975, a cerca de vinte anos não houve nenhuma publicação que tinha ligação na pesquisa em questão; em 1995, 1996 a frequência foi de um único artigo. Nenhum autor publicou mais de um trabalho durante período um período de 1995 até 1996. Foi o Constantinos S. Pattichis, Christos N. Schizas que publicou os dois artigos. O gráfico embaixo indica os artigos que foram publicados de 1975 até 1996.

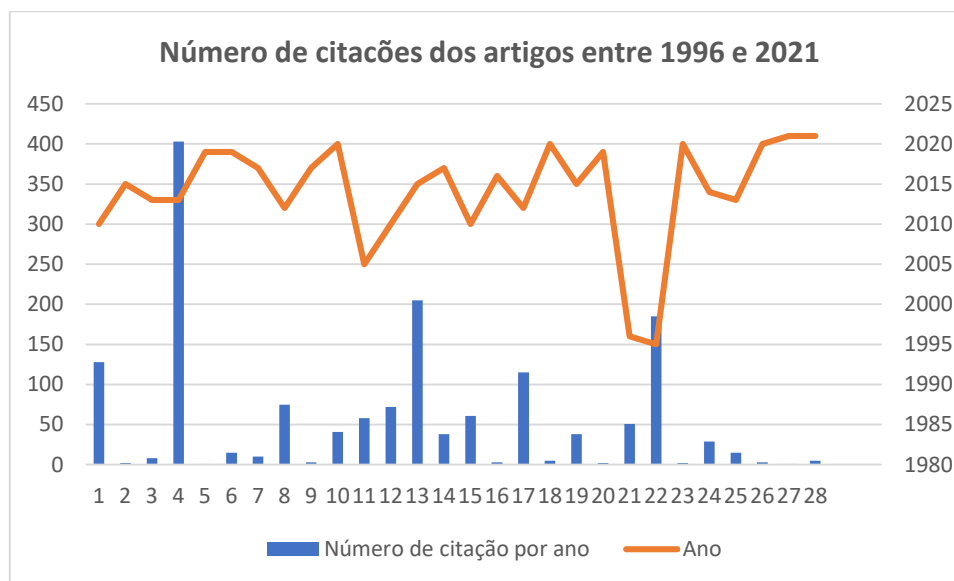
Figura 11 – Frequência dos artigos selecionados a partir de 1975 até 1996



Fonte: O Autor.

Na metodologia realizou-se uma filtragem dos artigos investigados. Estes artigos se encaixam em todos os fatores analisados nesta revisão sistemática. De início, encontrou-se um total de 78 artigos, sendo eles identificados nas bases de dados da IEEE Xplore, PubMed e Scopus. Na primeira seleção foram excluídos artigos duplicados e artigos de outras categorias diferentes de periódicos completos, de jornais e revistas. O segundo critério utilizado para filtragem foi a leitura dos resumos dos artigos, onde 38 artigos foram excluídos por não apresentarem o tema proposto e sim, apenas, palavras-chave em comum, totalizando 40 artigos selecionados. Dos 40 artigos selecionados para leitura completa, foram selecionados 30 artigos para esta revisão sistemática. Importante ressaltar, que as buscas, quando limitadas nos termos “AI” e “EMG”, apresentam um número elevado de artigos disponíveis nos bancos de dados, essa condição não se repete quando adicionado o termo “diagnóstico clínico (DC)”.

Figura 12 - Número de citações dos artigos



Fonte: O Autor.

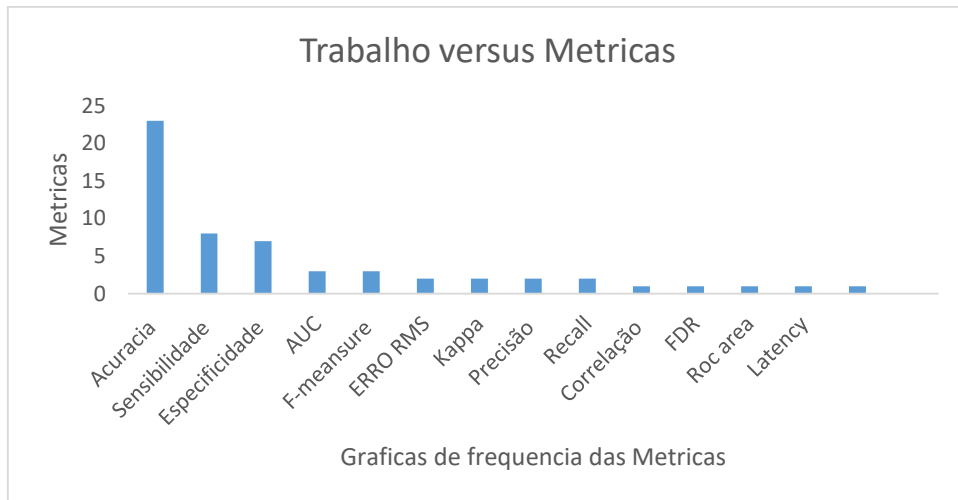
A figura acima indica o crescimento do número de citações nos primeiros dois anos, diminuindo em 1997, 1998 e 1999. Os anos de 2016, 2017, 2018, 2019, 2020 e 2021 acumulam 17% das citações. Na verdade, contamos mais de 1.572 citações publicadas de 1996 a 2021.

3.1 MÉTRICAS

Este artigo mostra o resultado de múltiplos fatores para interação entre EMG e inteligência artificial diretamente ligados na conclusão de DCs. Escolhe-se o fator métrico para a fidelidade dessas tecnologias aplicadas à prática clínica. As métricas são encontradas em todos os artigos investigados, os autores utilizam estes parâmetros como validação para a eficácia tanto no uso de EMG como em outras tecnologias, assim como para os DCs em geral.

Ao todo foram coletados 12 métricas diferentes, sendo elas, *Accuracy* (ACC), *Sensibility* (SEN), *Specificity* (SPE), *F-measure*, *Error RMS*, *Kappa*, *Precision*, *Recall*, *Correlation*, *False Detection Rate* (FDR), *Receiver Operating Characteristic curve* (ROC), *Area Under the Roc Curve* (AUC), *Latency*. A métrica mais apresentada foi a *Accuracy* com 88,62% dos artigos investigados, seguido pelas métricas de SEN e SPE com 29,63% e 22,22% respectivamente. Importante destacar que foram utilizadas mais de uma métrica por artigo. A *Erro!* Fonte de referência não encontrada, mostra as frequências com que cada métrica é utilizado nos diferentes artigos.

Figura 13 – Frequência com que cada métrica é utilizada nos diferentes



Fonte: O Autor.

3.2 VOLUNTÁRIOS

Este subtópico aborda as informações apresentadas, ou não, pelos artigos a respeito dos voluntários. A tabela abaixo indica as informações principais.

Tabela 3 – Informações fornecidas por voluntários.

Voluntários	Min.	Max.	Não informado
Total de voluntários (quantidade)	5	1674	1
Caso de controle (quantidade)	0	1478	14
Idade mínima (anos)	7	27	13
Idade máxima (anos)	30	94	13
Idade média (anos)	23,5	61,48	13
Feminino (montante)	0	140	7
Masculino (montante)	3	148	7

Fonte: O Autor.

A Tabela 3 mostra um trabalho que não apresentou informações sobre a quantidade de voluntários, além disso, esse mesmo trabalho não mostrou qualquer outra informação sobre os voluntários.

A idade mínima dos voluntários varia entre 7 e 27 anos, já a idade máxima variou entre 30 e 94 anos, sendo que 4 artigos não apresentaram informações de idade [12], [22], [26],

[30]. Os artigos [7], [8], [12], [15], [17], [21-22] não apresentavam importantes avaliações se os estudos controlados e bem delimitados. Os artigos [7], [9], [12], [16], [15], [21-22] não informaram sobre o sexo. Além disso, o trabalho [6] não investigou mulheres em seu estudo.

3.3 BIOSSINAIS, ELETRODOS E SISTEMA DE EMG

Esta revisão mostra que a eletromiografia de superfície (sEMG) foi utilizada na maioria dos estudos [6], [8], [10-11], [14-15], [17-18], [20-22], [25-32]; os demais utilizaram eletromiografia de agulha (iEMG) [7], [9], [12-13], [16], [23-24]. Apenas um trabalho publicado para (Terracina, Dan; Moniri, Ahmad; Rodriguez-Manzano, Jesus; Strutton, Paul H; Georgiou, Pantelis) que utilizou os dois tipos de eletrodos [19].


Quanto ao número de canais e ao *hardware* utilizado para aquisição do sinal EMG, observa-se que 11 estudos não informaram a quantidade de canais que foram utilizados. Também é possível verificar que a maioria dos estudos que trouxeram essa informação utilizou 1 canal.

3.4 PATOLOGIAS

Entre os artigos selecionados, foram encontrados 20 diferentes tipos de patologias/disfunções analisadas, com predominância da miopatia, abordada pelos artigos [7], [9], [13], [16], [23] e [24]. Verificando de forma analítica, foi observado que a EMG é utilizada principalmente para diagnosticar problemas associados ao sistema nervoso e problemas osteomioarticulares. Desta forma, os dados foram divididos em 3 grupos de patologias: osteomioarticular, sistema nervoso e outros, como apresentado na Erro! Fonte de referência não encontrada, onde podemos observar que apenas seis artigos não se enquadraram nos grupos osteomioarticular e sistema nervoso, ficando agrupados como “outros”, sendo eles [6], [12], [28], [29], [31] e [32].

No primeiro artigo usou-se a EMG para avaliar o equilíbrio durante atividades musculares. No décimo segundo artigo não foi informado nenhum tipo de patologia específica a ser diagnosticada. Apenas indivíduos hígidos foram testados, onde utilizaram EMG para antecipação de movimento em ambiente virtual. E, por fim, os sinais de EMG foram utilizados para classificação de fadiga em indivíduos hígidos.

Figura 14 – Patologias subdivididas




Fonte: O Autor.

3.4 MÚSCULO INVESTIGADO

Neste estudo a maioria dos artigos investigados utilizaram os seguintes músculos: Músculo Bíceps Braquial (MBB), Músculo Vasto Médio (MVM), Músculo Gastrocnêmio (MG), Músculo Tibial Anterior (MTA), Músculo Corrugador (MC), Músculo Vasto Lateral (MVL), Músculo Abductor Curto Polegar (MACP), Músculo Bíceps Femoral (MBF), Músculo Primeiro Interósseo Dorsal (MPID), Posicionado no Queixo (PQ), Músculo Reto Femoral (MRF), Músculo Semitendíneo (MS), Músculo Trapézio (MT), Músculo Abductor Longo Polegar (MALP), Músculo Adutor Polegar (MAP), Músculo Esplênio da Cabeça (MEC), Músculo Esternocleidomastóideo (ME), Músculo Extensor Antebraço (MEA), Músculo Extensor Dedos (MED), Músculo Extensor Indicador (MEI), Músculo Extensor Radial Carpo (MRC), Músculo Fibular Curto (MFC), Músculo Flexor Antebraço (MFA), Músculo Flexor Superficial Dedo (MFSD), Músculo Flexor Ulnar Carpo (MFUC), Músculo Glúteo Médio (MGM), Músculo Iliocostal (MI), Músculo Isquiotibiais Médios (MIM), Músculo Latíssimo Dorso (MLD), Músculo.

Levator Labii (MLL), Músculo Longuíssimo (MLG), Músculo Multifido (MM), Músculo Oblíquo Externo (MOE), Músculo Oblíquo Interno (MOI), Músculo Reto Abdominal (MRA), Músculo Semi-Espinhal da Cabeça (MSEC), Posicionado Sola do Pé (PSP), Músculo Sóleo (MS), Músculo Tenar (MTR), Músculo Tríceps (MTS), Músculo Zigomático (MZ), onde uma predominância na utilização de músculos dos membros superiores é facilmente observada. A fonte se relaciona os músculos analisados em cada artigo e ilustra a frequência de uso dos músculos para aquisição dos sinais EMG dos trabalhos investigados com mais de uma ocorrência.

Figura 15 - Frequência dos Músculos analisados



Fonte: O Autor.

Tabela 4 - Hardware e número de canais usados para adquirir EMG

Artigo	AUTOR /ANO	Músculos	Número de canais	Hardware EMG	Condição Clínica	Taxa de amostragem (Hz)	Passa-banda (Hz)
[6]	2010/ G. Hassan; Jafari, Roozbeh; P., Balakrishnan	MG, MTA	4	Delsys	Boa Saude	1000	450-20
[7]	2015/ Priyadharsini, Suja; Sonia, Bala; Deje	MBB	3	Medelec Synergy N2	Boa Saude	NI	NI
[8]	2013/ Hossen, Abdulnasir	MEA, MFA	2	NI		800	350-50
[9]	2013/ Subasi, Abdulhamit	MBB	NI	Medtronic Functional Diagnostics, Skovlunde, Denmark		20000	100-5
[10]	2012/ Izoubi, Omar; D'Mello, Sidney K; Calvo, Rafael A	MC	1	BIOPAC MP150 system		1000	NI
[11]	2016/ Umut, Ilhan; Centik, Guven	PQ	1	PSG device (Compumedics 44E series, Australia)		NI	NI
[12]	2019/ Nam, Sangwoo; Sohn, M. K.; Kim, H. A.; Kong, H. J.; Jung, I. Y	NI	1	Viking IV electrodiagnostic system		NI	NI
[13]	2020/ Subasi, Abdulhamit	MBB,MVM	1	EMGLAB v 1.03 (Simulador EMG)		NI	1000-2

[14]	2017/ Olsen, Anders Vinther; Stephansen, Jens; Leary, Eileen; Peppard, Paul E; Sheungshul, Hong; Jennum, Poul Jorgen; Sorensen, Helge; Mignot, Emmanuel	PQ, MTA	2	Sandman SD32+ amplifiers	512	NI-10
[15]	2014/ Zhang, Xu; Barkhaus, Paul E; Rymer, William Zev; Zhou, Ping	MPID	64	Refa128 EMG Recording System	2000	500-20
[16]	2012/ Subasi, Abdulhamit	MBB	1	EMG system da Medtronic Functional Diagnostics	20000	10000-5
[17]	2010/ Palmes, Paulito; Ang, Wei Tech; Widjaja, Ferdinan; Tan, Louis CS; Au, Wing Lok	MACP, MBB, MEI, MREC, MFUC, MTS	7	NI	2000	500-10
[18]	2013/ Manresa, José A Biurrun; Nguyen, Giang P; Curatolo, Michele; Moeslund, Thomas B; Andersen, Ole K	PSP, MTA	10	Neuroline 720	2000	500-5
[19]	2019	MI, MLD, MGL, MM, MOI, MOE, MRA	NI	NI	1000	450-20
[20]	2010/ Nair, Sumitra S; French, Robert M; Laroche, Davy; Thomas, Elizabeth	MBFI, MFC, MG, MGM, MS, MTA, MVL	NI	Kistler Instrumente AG	2000	400-20
[21]	2012 Conradsen, Isa; Beniczky, Sandor; Wolf; Kjaer, Troels W; Sams, Thomas; Sorensen, Helge BD	NI	14	Xsens MVN	1024	70-NI
[22]	2018/Uzun, Rukiye; Erkaymaz, Okan; Yapici, Irem Senyer	NI	NI	MWX8	1000	NI
[23]	2019/ Yaman, Emine; Subasi, Abdulhamit	MBB	NI	NI	20000	10000-5

[24]	2015/ Gokgoz, Ercan; Subasi, Abdulhamit	MBB, MVM	NI	NI	20000	2-10000
[25]	2017/ Shahin, Mostafa; Ahmed, Beena; Hamida, Sana Tmar-Ben; Mulaffer, Fathima Lamana; Glos, Martin; Penzel, Thomas	NI	NI	NI	200	NI
[26]	2020/ Parisi, Luca; RaviChandran, Narrendar	MBF, MG, MIM, MRF, MS, MVM,	NI	NI	2400	400-20
[27]	2020/ Ricciardi, Carlo; Jonsson, Halldor; Jacob, Deborah; Improta, Giovanni; Recenti, Marco; Gislason, Magnus Kjartan; Cesarelli, Giuseppe; Esposito, Luca; Minutolo, Vincenzo; Bifulco, Paolo; others	MRF, MVL, MVM	NI	KINE view, GAITRite and KINE EMG	1600	NI
[28]	2015/ Gruss, Sascha; Treister, Roi; Werner, Philipp; Traue, Harald C; Crawcour, Stephen; Andrade, Adriano; Walter, Steffen	MC, MT	NI.	Nexus-32 amplifier	NI	NI
[29]	2010/ Choi, Changmok; Kwon, Suncheol; Park, Wonil; Lee, Hae-dong; Kim, Jung	MACP, MALP, MAP, MED, MFSD, MPID	6	DE-2.1, Delsys	NI	NI
[30]	2020/ Drimalla, Hanna; Scheffer, Tobias; Landwehr, Niels; Baskow, Irina; Roepke, Stefan; Behnia, Behnoush; Dziobek, Isabel	MLL, MZ	NI.	NI	NI	NI
[31]	2005/ Barniv, Yair; Aguilar, Mario; Hasanbelliu, Erion	ME, MSEC, MEC, MT	16	Neuroscan SynAmps	2000	500-10
[32]	2021/ Wuxiang Shi, Yurong Li, Dujian Xu,	VM, MBFI, MFC, MG, MGM,	NI	biomecânica	27 pacientes com dor	NI 30-6

	Chen Lin, Junlin Lan, Yuanbo Zhou, Qian Zhang, Baoping Xiong and Min Du	MS, MTA, MVL, VL, MG, BF			femoropatelar/ 16 grupos de controle sem dor		
[31]	2021/Fahmida Haque, Mamun B.I.Reaz, Muhammad E.H. Chowdhry, Fazida	VL, GM, TA	NI	classificador de gravidade DSPN baseado em ANFIS	pacientes DSPN com diferentes níveis de gravidade	10543	NI

Fonte: O Autor.


3.5 EXTRAÇÃO DE CARACTERÍSTICAS

No processo de desenvolvimento de um classificador de inteligência artificial é importante identificar as variáveis de entrada ao sistema. Embora alguns estudos não apresentem informações detalhadas sobre o pré-processamento de dados [29-30], a extração de características é um processo vital quando usados sistemas de inteligência artificial.

Os sinais de EMG são tradicionalmente submetidos a filtros de diferentes tipos e diferentes frequências de corte. O filtro mais comum é o filtro *band-pass* com frequências de corte 20 e 450 Hz. Alguns autores utilizam diretamente os sinais filtrados de EMG para desenvolver os classificadores [12], [20], [26]. No entanto, é comum que após o processo de filtragem sejam extraídas diferentes características, segundo o processo utilizado.

As características do tipo estatística são as mais usadas, incluindo principalmente *mean*, *median*, *standard deviation*, *maximal*, *minimal* e *zero-crossing* dos sinais de EMG, tanto no domínio do tempo [6], [10], [15], [17-18], [27], quanto no domínio da frequência [28], [31-32], também como alguns indicadores destas variáveis como os *Hjorth Parameters* [14], [25]. Por outro lado, para definir as características de entrada ao sistema, alguns autores utilizam transformadas de *wavelet* em conjunto com variáveis estatísticas [7], [9], [13], [16], [21-23], também como algoritmos de principal *component analysis* PCA para redução da dimensão da base de dados [24], *forecasting* [19] e algoritmos para mensurar a energia dos sinais [8], [11].

Figura 16 – Técnicas aplicadas para extração de recursos




Fonte: O Autor.

3.6 CLASSIFICADORES

Após a extração de características, aplica-se um classificador para definir e separar o maior número de categorias presentes nos dados. Ao escolher o classificador é importante definir corretamente sua estrutura. A obtenção de classes 0 2 4 6 8 10 12 14. Dados estatísticos wavelet RAW, Domínio de Frequência, PCA Previsão sem informação, números de estudos, extração de características técnicas aplicadas para extração de recursos por categorias resultará no entendimento e no aproveitamento dos dados como ferramenta para atuação do sistema implementado, onde 29,63% dos artigos investigados utilizaram o *Support Vector Machine* (SVM) como classificador [9-10], [16-17], [21], [26], [28-29]. Entre os mais utilizados estão os classificadores *Artificial Neural Network* (ANN), *K-Nearest Neighbor* (KNN) [6], [9-11], [18], *Linear Discriminant Analysis* (LDA) [14-15], [19-20], *Random Forest* (RF). Na Tabela 3 é possível verificar as frequências com que os classificadores são empregados nos trabalhos investigados, enquanto na Figura 8 apresentam as técnicas de extração de características, classificadores e suas métricas.

Figura 17 - Informações fornecidas pelos classificadores




Fonte: O Autor.

3.7 PLATAFORMAS DE SOFTWARE

No desenvolvimento das tarefas de análise e formatação dos dados dos sinais, extração de características, classificação e avaliação dos resultados, podem ser escolhidas diferentes plataformas de *software* com linguagem de programação, ambientes de desenvolvimento, ferramentas de visualização de dados, entre outras funcionalidades importantes. Quatro artigos [12-13], [17] e [31] informaram a utilização de mais de uma plataforma de *software*, sendo que [12] utilizou CUDA, cuDNN, Python e TensorFlow. Dentre os 27 artigos avaliados, 11 artigos [6], [10], [13-15], [17], [20], [26], [29] e [31] usaram Matlab, entretanto, 8 artigos [8-9], [16], [22-25] e [27] não informaram as ferramentas de *software* utilizadas. Python é utilizado em três artigos [12], [28] e [30], enquanto C [19] e [31], LabView [7] e [17] e WEKA [11] e [13] foram usados por dois artigos cada. CUDA cuDNN e TensorFlow aparecem em apenas um trabalho [12] juntamente com Python. A Figura 7 ilustra a frequência das plataformas de *softwares* utilizados nos trabalhos analisados.

Figura 18 – Frequência das plataformas de software utilizadas nos trabalhos



Fonte: O Autor


Tabela 5 – Parâmetros e métricas de trabalhos de inteligência artificial.

Artigo	Recursos	Classificadores	Métricas	Plataforma de software e eficácia
[1]	Estatísticas	ANN, KNN	ACC	Matlab, 93,53%
[2]	Estatísticas, Wavelets	MBB	ACC	Labview, NI
[3]	Wavelets	ANN	ACC	NI , 87,5%.
[4]	Estatísticas, Wavelets	KNN, PSO, RBFN, SVM	NI	NI, 97,41%
[5]	Estatísticas	C.45, KNN, NBayes, Regressão, SVM	F-measure, Kappa	Matlab, 93,8%
[6]	tatísticas, Fourier, Wavelets	ANN, KNN, RForest, Regressão	ACC	WEKA, 99.08%
[7]	Raw	CNN	ACC, Precisão, Recall	CUDA, cuDNN, Python, TensorFlow, NI
[8]	Estatísticas, Wavelets	RForest	ACC	Matlab, WEKA, NI
[9]	Hjorth	LDA	ACC	Matlab, NI
[10]	Statísticas	LDA	SPE, SEN	Matlab
[11]	Estatísticas, Wavelets	SVM	ACC	NI
[12]	Estatísticas	SVM	ACC	Labview, Matlab
[13]	Estatísticas	KNN	ACC	Neuroline 720
[14]	Forecasting	CVM	ACC	NI
[15]	Raw	Boosting, RForest	ACC	C
[16]	Log-Sum, Wavelets	SVM	FDR, LAT, SEN	Matlab
[17]	Wavelets	ANN, Regressão	ACC, SPE, SEN	MWX8
[18]	Estatísticas, PCA, Wavelets	Bagging, AdaBoosting, Multiboosting	ACC, F-measure, Kappa, ROC	NI
[19]	Estatísticas, PCA, Wavelets	C.45, CART, PSO	ACC, AUC, SPE, SEN, Fmeasure	NI
[20]	Amplitude, Espectral, Estatísticas, Hjorth, ZC	DNN	ACC	NI

[21]	Raw	SVM	ACC, AUC, SPE, SEN	NI
[22]	Estatísticas	Boosting, RForest	ACC, AUC, SPE, SEN, Precisão, Recall	NI
[23]	Amplitude	SVM	ACC, SPE, SEN	Python
[24]	NI	ANN, SVM	Correlação, Erro RMS	Matlab
[25]	NI	ENN	ACC, SEN	Python
[26]	Amplitude, Espectral, Estatísticas, PCA, ICA, ZC	ACC, SEN	Erro RMS	C, Matlab
[27]	NI	CPS, RForest	ACC	NI
[28]	Statísticas	ANN	SPE, SEN, Precisão, Recall	Matlab, 83,5%.
[29]	Estatísticas, Wavelets	ANN	ACC	Matlab, NI
[30]	NI	Bagging, AdaBoosting, Multiboosting	ACC, F-measure	Matlab

Fonte: O Autor

Figura 19 - Estado das citações dos artigos revisados entre 1996 e 2021



Fonte: O Autor

4 DISCUSSÃO

Perante os artigos estudados ficou evidente que durante dos anos a utilização de métricas como ACC e relações entre SEN e SPE são as mais utilizadas para o desenvolvimento de diagnósticos clínicos integrados com AI e EMG. A integração de mais de uma métrica por artigo também se apresentou repetidamente ao longo desta investigação, apresentando alto desempenho, garantindo assim eficácia. Para aperfeiçoamento e maior taxa de aceitabilidade dos resultados e implementações autores utilizaram mais de uma métrica sendo *Precision e Recall*, para o artigo 10 a integração entre SEN e SPE foram suficientes. Já [17] utilizou FDR, LAT e ROC Curve comparando as extrações de características com *Discrete Wavelet Transform* (DWT) e *Wavelet Packet Transform* (WPT), os autores [17] e [23] apresentam as métricas entre SEN e SPE juntamente com ACC. Os autores de [18] utilizaram ACC, *F-measure*, *Kappa e Roc Curve*, [21] utilizaram AUC, SEN e SPE, [22] utilizaram AUC, SEN, SPE, *Precision, Recall* e ACC, para os autores de [24] integraram Correlação e *Error RMS*. Outros artigos investigados apresentam apenas uma métrica como fator conclusivo. É possível analisar a interação das métricas.

Para garantir que os resultados das métricas apresentados por determinado estudo sejam fidedignos, o desenvolvimento do método proposto deve reduzir o risco de viés. Como parte desse processo, a aquisição do sinal EMG deve ser realizada adotando-se um padrão baseado em evidências científicas, para garantir a qualidade dos dados adquiridos.

Os protocolos para aquisição do sinal EMG contém descrição das características do sensor, localização do sensor, anatomia dos músculos e testes para verificar a correta disposição do sensor. Bem como métodos adequados para pré-processamento, processamento e análise do sinal. Durante a aquisição do EMG os eletrodos captam o sinal e ruídos simultaneamente. Portanto, o eletro miógrafo deve ser confiável para selecionar o sinal desejado e, assim, dar fidelidade ao diagnóstico. Devemos ser menos impactados, já que não há relato do equipamento em todos os artigos, como indica a Tabela 4.

Ainda sobre a aquisição dos sinais, as características dos eletrodos precisam ser adequadamente definidas, incluindo a escolha do tipo de eletrodo. Quanto a isso e como mostrado anteriormente, 74% dos estudos empregaram sEMG. Devemos minimizar a impedância pele/eletrodo, tomando certos cuidados, como limpeza da pele, remoção dos pelos e leve abrasão para remoção das células mortas para uma boa qualidade na aquisição do sinal eletromiográfico. O local e o posicionamento dos eletrodos também se tornam fundamentais e relevantes, devendo ser considerados alguns aspectos fundamentais, como a localização do ponto motor, referência para a colocação do eletrodo, devendo ser colocado entre o ponto motor e o tendão do músculo a ser avaliado. O outro aspecto a se considerar são as interferências, como batimentos cardíacos, contrações de músculos vizinhos (*“cross-talk”*) e artefatos eletromecânicos. Os eletrodos devem ser alinhados na mesma direção das fibras musculares para coincidir com a direção potencial de ação. Por fim, há o aspecto do eletrodo de referência, que deve ser colocado nas regiões do punho, tornozelo ou processo espinhal CVII. As recomendações do SENIAM (*Surface Electromyography for Non-Invasive*

Assesment of Muscles), com relação à utilização dos filtros analógicos, são, a passa baixa, com frequência de corte de 500Hz, aplicado para promover uma atenuação dos componentes de frequência e ruído e a passa alto, com frequência de corte menor que 10 Hz para análise espectral e 10-20 Hz para análises do movimento (HERMENS *et al.* 2000).

Segundo Sampaio (2000), “a avaliação da atividade eletromiográfica é registrada utilizando-se um eletrodo terra e quatro eletrodos bipolares de superfície, conectados a um eletromiógrafo por meio de cabos”. Os sinais eletromiográficos são enviados a dois pré-amplificadores universais. Foi preparada a superfície da pele do indivíduo sobre os músculos masseteres com álcool 70°, para remover o excesso de oleosidade. Um par de eletrodos com pasta de condutividade, para facilitar o contato dos mesmos com a pele, é colocado sobre o masseter do paciente sentado, com a mandíbula perfazendo um ângulo de 45°.

Em conformidade com Landulpho (2003), “existem dois tipos de eletrodos utilizados para captar a eletromiografia, os de superfície e os de inserção. Ambos podem ser monopolares ou bipolares e apresentam características específicas para seu uso”.

Os eletrodos de superfície ou de pele podem ser classificados como passivos ou ativos. Quando ativos ou secos, não necessitam de preparação da pele com gel ou pasta. O potencial de polarização na junção do eletrodo pode variar com a temperatura, sudorese, ressecamento da pasta condutora e movimento do eletrodo ou da pele. Uma consideração importante quanto ao uso dos filtros para o alisamento do sinal eletromiográfico baseia-se em um atraso no processamento, que pode ser removido se realizada a filtragem. Uma vez adquirido o sinal eletromiográfico, existem muitos métodos de processamento que podem ser utilizados para a interpretação dos dados. Duas características importantes do sinal eletromiográfico são a frequência e a amplitude. Eletrodo, termo de origem grega, que significa via, de maneira geral, é o terminal, polo, responsável pela conexão entre um circuito elétrico e uma parte não-metálica. Esse material deve ser constituído por um condutor de eletricidade, com objetivo de proporcionar uma transferência de elétrons entre o circuito e o meio conectado (ROBERTSON, 2004).

A atividade elétrica dos músculos mastigatórios em crianças portadoras de mal oclusão tem sido abordada na literatura no intuito de comparar o lado direito com o esquerdo, através da utilização de eletromiografia. Os sinais mioelétricos foram captados por meio da colocação de eletrodos ativos de superfícies diferenciais (ganho de vezes, 10 mm de distância entre as superfícies de detecção), e um eletrodo de referência com área de 3cm^2 foi posicionado no osso frontal em um estudo. Para aquisição dos sinais, foram utilizados canais simultâneos e filtro passa faixa de 10 a 500 Hz. Para realização da coleta de dados, os indivíduos foram instruídos a permanecer sentados, com plano horizontal de Frankfurt paralelo ao solo. “A limpeza da pele foi feita com álcool 70% para diminuir a impedância entre pele e eletrodo, sendo que o sinal foi avaliado em três situações diferentes. Através deste protocolo de colocação, os resultados foram obtidos de forma satisfatória” (BEVILAGUA-GROSSI, 2005).

Referindo com Cesar *et al* (2005), para a coleta do sinal, foram utilizados quatro eletrodos de superfície e, para redução de ruído Cesar *et al.* (2005), para a coleta do sinal,

foram usados quatro eletrodos de superfície e, para redução de ruídos de aquisição, foi utilizado um eletrodo de referência (terra), sendo este untado com gel à base de água em sua interface e fixado na região anterior da porção distal do antebraço do paciente. A coleta de sinais iniciou com a limpeza da pele e adequada colocação dos eletrodos ativos diferenciais de superfície, os quais foram orientados de acordo com a disposição das fibras musculares, sendo cada eletrodo posicionado no ventre dos músculos, segundo protocolo do Laboratório de Eletromiografia da FOP-UNICAMP.

Os eletrodos devem ser colocados paralelamente às fibras do músculo que se deseja analisar. Também é importante garantir que os eletrodos estejam próximos ao ponto de maior atividade elétrica. Devemos tomar cuidado com os músculos adjacentes, pois, se estiverem muito próximos, pode ocorrer *crosstalk*. “Não podemos deixar de colocar o eletrodo terra em boa área de contato” (BIASOTO-GONZALES, 2005). “As atividades eletromiográficas dos músculos masseter e temporal anterior foram avaliadas em pacientes assintomáticos e com mal oclusão de classe I, utilizando-se eletrodos bipolares de superfície para os registros eletromiográficos em dois momentos, em repouso e em apertamento oclusal máximo, não apresentando variação significativa” (SANTOS, 2006).

A qualidade do sinal eletromiográfico amplificado pode ser mensurada através da razão sinal/ruído. O sinal de modo comum é aquele detectado em ambos os eletrodos, tais como interferências da rede elétrica, entre outras, se fazendo necessária a presença de filtros. Devemos selecionar, ajustar um filtro e analisar os dados, então adaptar o comprimento de banda ao filtro ideal do sinal. O filtro é um dispositivo designado para atenuar variações específicas de frequência. Os filtros possuem duas utilidades importantes, ou seja, de separação e de restauração do sinal. A separação do sinal é necessária quando este for contaminado com alguma interferência, ruído ou outro sinal. A restauração do sinal é utilizada quando este foi distorcido de alguma forma. Portanto a função dos filtros é permitir a passagem de algumas frequências inalteradas e atenuar outras. Os filtros podem ser analógicos ou digitais, os analógicos são baratos, rápidos, possuem grande variação dinâmica e são relacionados ao condicionamento do sinal. Os digitais são superiores em seu nível de desempenho e muito requisitados para análise dos dados após sua digitalização (KONRAD, 2005).

Segundo Gomes (2006) “realizou um estudo com o objetivo de mensurar e comparar a atividade dos músculos masseter, temporal e bucinador em diferentes métodos de alimentação de lactentes, através da realização de eletromiografia com eletrodos de captação de superfície durante a alimentação, sendo o eletrodo de superfície o que apresenta melhores resultados”. Normalmente são utilizados eletrodos superficiais passivos, isto é, que não possuem amplificação no próprio eletrodo. Este tipo de eletrodo apenas detecta o sinal eletromiográfico e o envia ao condicionador (amplificador associado ao filtro analógico). Em função da baixa amplitude do sinal eletromiográfico durante a aquisição, faz-se necessário amplificar o sinal para processamento. “Entretanto, cuidados devem ser tomados para que não se modifique sua característica” (MARCHETTI; DUARTE2006).

Todos os outros trabalhos não descreveram adequada e detalhadamente a escolha do local e posicionamento dos eletrodos, ou ainda, apresentaram um posicionamento que não seguem a nomenclatura internacional. Esta falta de detalhes na coleta dos dados pode promover uma fragilidade nos classificadores, devido ao aumento de ruídos no sinal de EMG, limitação dos padrões de movimento e até mesmo aumentando o risco de viés. É evidente que a eficiência no diagnóstico clínico por AI depende diretamente da integração de múltiplos fatores na arquitetura escolhida para o processamento dos dados e resultados. Para que as métricas obtenham alto desempenho os protocolos de aquisição, extração e classificação seguem uma linha estrutural, sendo ela, aquisição de dados, que neste caso são biosinais, a extração de características, a escolha de classificadores para seleção e separação dessas características e por fim as métricas, responsáveis por gerir os dados já classificados e organizados. Como discutido até este momento, cada fator influencia nos resultados, isso não é diferente com os classificadores, apresentam-se as interações de múltiplos classificadores em um mesmo projeto, como por exemplo os artigos [11], [20], [24] e [31].

O *software* MatLab é o ambiente de desenvolvimento mais utilizado no diagnóstico clínico por AI, o uso desta plataforma permanece ao longo dos anos, notavelmente há alterações nas interfaces e nos hardwares de aquisição que evoluem tecnologicamente, no entanto a plataforma se mantém como base e interpretação das linguagens de programação. Isso fica evidente quando em um espaço de tempo de 15 anos ainda se utiliza a mesma plataforma em investigações completamente diferentes [27], [31].

5 CONSIDERAÇÕES FINAIS

Nossa análise bibliométrica se baseia no pressuposto de que a publicação em periódicos científicos é um bom sinal do surgimento e desenvolvimento de ideias científicas.

Foi analisado neste trabalho 30 artigos que usam sinal EMG e AI para auxiliar em DCs e em avaliação de condições clínicas.

Os resultados do presente artigo mostraram que a associação de EMG e AI pode auxiliar os profissionais de saúde no DC de doenças e condições clínicas. Entretanto, a utilização de algoritmos não garante que erros de aquisição do sinal EMG não ocorram. Dessa forma, erros de extração do sinal EMG devem ser evitados empregando-se, rigorosamente, métodos padrões para exames de eletromiografia.

Os métodos estatísticos foram os mais utilizados para caracterização da EMG, pela necessidade de quantificação das características do sinal EMG.

Para finalizar, foi identificado que *Support Vector Machine*, *Artificial Neural Network*, *K-Nearest Neighbor*, *Random Forest* e *Linear Discriminant Analysis* foram (Hassan Ghasemzadeh, 2020) os algoritmos de classificação mais utilizados dentre os 30 artigos analisados.

REFERÊNCIAS

ALZOUBI, O.; D'MELLO, S. K.; CALVO, R. A. Detectando expressões naturalísticas de afeto não básico usando sinais fisiológicos. *IEEE Transactions on affective computing*, São Paulo, v. 3, nº 3, 2012.

BARNIV, Y.; AGUILAR, M.; HASANBELLIU, E. Usando EMG para antecipar o movimento da cabeça para Aplicativos de ambiente virtual. *IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING*, VOL. 52, NO. 6 de junho de 2005

DRIMALLA, H. *et al.* **RUMO À DETECÇÃO AUTOMÁTICA DE BIOMARCADORES SOCIAIS NO TRANSTORNO DO ESPECTRO DO AUTISMO**: introduzindo a tarefa de interação simulada (SIT). Disponível em: <https://www.nature.com/npjdigitalmed/> Acesso em 14 set. 2021.

GHASEMZADEH, H. JAFARI, R. PRABHAKARAN, B. 198 Transactions on information technology in biomedicine, Vol. 14, nº 2 de março 2010.

HOSSEN, A. Uma abordagem de rede neural para extração de características e discriminação entre temor parkinsoniano e tremor essencial. *Technology na Health Care* 21 (2013), p. 345-356. DOI 10.3233 / THC-130735.

MANRESA, J. A. B. *et al.* **Modelo probabilístico para avaliação individual de hiperexcitabilidade central usando o reflexo de retirada nociceptivo**: um biomarcador para dor lombar e cervical crônica. Disponível em: <https://bmcneurosci.biomedcentral.com/articles/10.1186/1471-2202-14-110>. Acesso em: 20 set. 2021.

OLSEN, A.V. *et al.* Valor diagnóstico da dissociação do estágio do sono, conforme visualizado em um espaço de estado de sono bidimensional na narcolepsia humana. Disponível em: <http://dx.doi.org/10.1016/j.jneumeth.2017.02.004>. Acesso em: 23 set. 2021.

PALMES, P. *et al.* Mineração de padrões de semg multicanal para classificação de Tremor. *IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING*, VOL. 57, NO. 12, DEZEMBRO DE 2010.

PRIYADHARDINI, S. BALA, S. Técnica híbrida de ELM-wavelet para a classificação e diagnóstico de desordem neuromuscular usando sinal EMG. ISSN: 0976-3104. Vol. 6. Priyadharsini, 2015.

SANGO, N. *et al.* Desenvolvimento de inteligência artificial para apoiar análise diagnóstica de eletromiografia de agulha. Disponível em: <http://creativecommons.org/licenses/bync/4.0/> Acesso em: 20 set. 2021.

SUBASI, A. Diagnóstico de doenças neuromusculares usando DT-CWT e floresta de rotação. Disponível em: <http://www.ieee.org/publications/rights/index.html>. Acesso em 20 set. 2021.

SUBASI, A. Sistema de apoio à decisão médica para diagnóstico de doenças neuromusculares usando DWT e máquinas de vetor de suporte fuzzy. Disponível em: <http://dx.doi.org/10.1016/j.compbiomed.2012.06.004> Acesso em: 20 set. 2021.

SUBASI, A. Classificação de sinais EMG usando CVM otimizado para PSO para diagnóstico de doenças neuromusculares. Disponível em: <http://dx.doi.org/10.1016/j.compbiome.2013.01.020>. Acesso em: 22 set. 2021.

SUMITRA, S.N. *et al.* A Aplicação de Algoritmos de Aprendizado de Máquina à Análise de

Padrões Eletromiográficos De pacientes com artrite. IEEE TRANSACTIONS ON NEURAL SYSTEMS AND REHABILITATION ENGINEERING, VOL. 18, NO. 2, ABRIL 2010.

TERRACINA, D. *et al.* Previsão e classificação em tempo real da fadiga muscular do tronco usando eletromiografia de superfície. ISSN 978-1-5090-0617-5.

UMUT, I.; ÇENTIK, G. Detecção de movimentos periódicos da perna por métodos de aprendizado de máquina usando parâmetros polissonográficos diferentes da eletromiografia de perna. Disponível em: <http://dx.doi.org/10.1155/20166/2041467>. Acesso em 20 set. 2021.

UZUN, R.; ERKAYMAN, O.; YAPICI, I. S. Comparação de redes neurais artificiais e modelos de regressão para diagnosticar distúrbios do joelho em diferentes posturas usando eletromiografia de superfície. Disponível em: <http://dergipark.gov.tr/gujs>. Disponível em: 23 set. 2021.

YAMAN, E.; SUBASI, A. Comparação de bagging and boosting ensemble machine learning methods for automated EMG signal classification. Disponível em: <https://www.hindawi.com/journals/bmri/2019/9152506/> Acesso em: 20 set. 2021.

ZHANG, X. Aprendizado de máquina para apoiar o diagnóstico de esclerose lateral amiotrófica usando superfície eletromiograma. Disponível em: http://www.ieee.org/publications_standards/publications/rights/index.html. Acesso em: 15 set. 2021.