



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO DE CIÊNCIAS DA SAÚDE
PROGRAMA DE PÓS-GRADUAÇÃO DO MESTRADO PROFISSIONAL EM
INFORMÁTICA EM SAÚDE

MICHELL HENRIQUE SCHWAB

**ANÁLISE PREDITIVA COM APRENDIZADO DE MÁQUINA DA RECUPERAÇÃO
DA MOBILIDADE FUNCIONAL DOS PACIENTES HOSPITALIZADOS
ATENDIDOS PELO SERVIÇO DE FISIOTERAPIA**

FLORIANÓPOLIS

2021

MICHELL HENRIQUE SCHWAB

**ANÁLISE PREDITIVA COM APRENDIZADO DE MÁQUINA DA RECUPERAÇÃO
DA MOBILIDADE FUNCIONAL DOS PACIENTES HOSPITALIZADOS
ATENDIDOS PELO SERVIÇO DE FISIOTERAPIA**

Dissertação submetida ao Programa de Pós-Graduação
do Mestrado Profissional em Informática em Saúde da
Universidade Federal de Santa Catarina para a obtenção
do título de Mestre em Informática em Saúde.

Orientador: Prof. Dra. Sayonara de Fátima Faria
Barbosa

Coorientador: Prof. Dr. Alexandre Gonçalves Silva

FLORIANÓPOLIS

2021

Ficha de identificação da obra

SCHWAB, MICHELL HENRIQUE. Análise preditiva com Aprendizado de Máquina da recuperação da mobilidade funcional dos pacientes hospitalizados atendidos pelo Serviço de Fisioterapia. / MICHELL HENRIQUE SCHWAB; orientador, SAYONARA DE FÁTIMA FARIA BARBOSA, coorientador, ALEXANDRE GONÇALVES SILVA, 2021. 94 p.

Dissertação (Mestrado Profissional) - Universidade Federal de Santa Catarina, Centro de Ciências da Saúde, Programa de Pós-Graduação em Informática em Saúde, Florianópolis, 2021.

Inclui referências.

1. Informática em Saúde. 2. Mobilização Física. 3. Fisioterapia Hospitalar. 4. Aprendizado de Máquina. 5. Redes Neurais Artificiais. I. BARBOSA, SAYONARA DE FÁTIMA FARIA. II. SILVA, ALEXANDRE GONÇALVES. III. Universidade Federal de Santa Catarina. Programa de Pós-Graduação em Informática em Saúde. IV. Título.

MICHELL HENRIQUE SCHWAB

Título: Análise preditiva com Aprendizado de Máquina da recuperação da mobilidade funcional dos pacientes hospitalizados atendidos pelo Serviço de Fisioterapia.

O presente trabalho em nível de Mestrado foi avaliado e aprovado por banca examinadora composta pelos seguintes membros:

Profa. Dra. Sayonara de Fátima Faria Barbosa
Universidade Federal de Santa Catarina

Prof. Dr. Jefferson Luiz Brum Marques
Universidade Federal de Santa Catarina

Prof. Dra. Nayala Lirio Gomes Gazola
Fisioterapeuta – HU/UFSC

Certificamos que esta é a **versão original e final** do trabalho de conclusão que foi julgado adequado para obtenção do título de Mestre em Informática em Saúde

Dra. Grace Terezinha Marcon Dal Sasso
Coordenadora do Programa de Pós-Graduação

Dra. Sayonara de Fátima Faria Barbosa
Orientadora

Florianópolis, 2021.

AGRADECIMENTOS

Agradeço à minha família, em especial aos meus pais, esposa e filha pelo apoio recebido.

Aos meus colegas do curso de mestrado.

As diversas pessoas que direta ou indiretamente possibilitaram que o estudo fosse realizado.

Ao Serviço de Fisioterapia do HU-UFSC, que disponibilizou o conjunto de dados para a aplicação na pesquisa e realiza um trabalho brilhante na reabilitação hospitalar.

Aos meus orientadores, professores Dra. Sayonara e o Dr. Alexandre, ressaltando a paciência e dedicação de seu tempo em todo o processo de desenvolvimento do estudo.

RESUMO

A perda de mobilidade acarreta prejuízos pessoais, psicológicos, sociais, financeiros e é um fenômeno comum naqueles pacientes restritos ao leito. A diminuição da atividade física e o repouso no ambiente hospitalar contribui para piora da recuperação do paciente, associado ao aumento dos riscos à saúde, como o declínio na capacidade de realizar atividades da vida diária, institucionalização e morte. No contexto de baixa mobilidade funcional, o serviço de fisioterapia atua na avaliação e conduta, com o objetivo de prevenir, manter ou melhorar a mobilidade física, atuando em diversas desordens corporais. Uma ferramenta que pode ser utilizada para medição e auxílio na recuperação da funcionalidade dos doentes é a inteligência artificial, especificamente, o Aprendizado de Máquina, onde algoritmos fazem previsões para interpretar dados e aprender sem instruções programadas. Nesse cenário, a pesquisa tem por objetivo desenvolver uma modelagem de Aprendizado de Máquina para predição da mobilidade funcional dos pacientes internados em enfermarias, que receberam atendimento fisioterapêutico. Esse estudo é considerado metodológico e de desenvolvimento tecnológico. A pesquisa foi desenvolvida, a partir dos dados coletados em um Hospital Universitário, com os dados dos pacientes internados em unidade de clínica médica e cirúrgica que foram avaliados e atendidos pelo serviço de fisioterapia, durante o ano de 2020, sendo excluídos óbitos e menores de idade. Para o desenvolvimento do modelo foram utilizados 22 atributos com 1.386 registros do conjunto de dados, sendo definidos os previsores e a classe com o desfecho de independência ou dependência física. Foi utilizada a linguagem de programação Python e suas bibliotecas Panda, Numpy, Matplotlib, Sklearn e Keras. O classificador da rede neural artificial foi desenvolvido, com 21 entradas, três camadas ocultas com 11 neurônios em cada e uma saída. Quanto aos resultados, a validação cruzada apontou a acurácia de 93.21%, com o desvio padrão de 0,030, enquanto a matriz de confusão obteve 92,44% de acurácia. Além disso, a área abaixo da curva (AUC) da curva ROC atingiu 0,934, que mediu a capacidade do modelo de prever uma pontuação maior de exemplos positivos em comparação com os exemplos negativos. Portanto, a partir das métricas de avaliação pode-se afirmar que o modelo apresenta um bom desempenho e uma boa capacidade de generalização.

Palavras-chave: Mobilidade Física. Fisioterapia. Aprendizado de Máquina. Redes Neurais Artificiais.

ABSTRACT

Loss of mobility entails personal, psychological, social, financial losses and is a common phenomenon in patients confined to bed. The decrease in physical activity and rest in the hospital environment contributes to worsening the patient's recovery, associated with increased health risks, such as the decline in the ability to perform activities of daily living, institutionalization and death. In the context of low functional mobility, the physiotherapy service acts in the assessment and conduct, with the objective of preventing, maintaining or improving physical mobility, acting on various bodily disorders. A tool that can be used to measure and assist in recovering patient functionality is artificial intelligence, specifically Machine Learning, where algorithms make predictions to interpret data and learn without programmed instructions. In this scenario, the research aims to develop a Machine Learning model to predict the functional mobility of patients admitted to wards, who received physical therapy care. This study is considered methodological and technological development. The research was developed from data collected at a University Hospital, with data from patients admitted to a medical and surgical clinic unit who were evaluated and treated by the physiotherapy service during the year 2020, excluding deaths and minors. For the development of the model, 22 attributes with 1,386 records of the dataset were used, being defined the predictors and the class with the outcome of independence or physical dependence. The Python programming language and its Pandas, Numpy, Matplotlib, Sklearn and Keras libraries were used. The artificial neural network classifier was developed, with 21 inputs, three hidden layers with 11 neurons each and one output. As for the results, the cross validation showed the accuracy of 93.21%, with a standard deviation of 0.030, while the confusion matrix had 92.44% accuracy. In addition, the area under the curve (AUC) of the ROC curve reached 0.934, which measured the model's ability to predict a higher score for positive examples compared to negative examples. Therefore, from the evaluation metrics it can be stated that the model has a good performance and a good generalizability.

Key words: Physical Mobility; Physiotherapy; Machine Learning; Artificial neural networks.

LISTA DE FIGURAS

Figura 1 - Modelo Típico de Redes Neurais	44
Figura 2 - Protocolo de Mobilização Precoce	57
Figura 3 - Modelo da Rede Neural Artificial	62
Figura 4 - Validação Cruzada.....	67
Figura 5 - Matriz de Confusão.....	67
Figura 6 - Relatório de Classificação	68
Figura 7 - Acurácia, Precisão, Sensibilidade, Especificidade e F1_Score	68
Figura 8 - Curva ROC da Rede Neural	69
Figura 9 - Curva ROC dos classificadores	70

LISTA DE QUADROS

Quadro 1 - Protocolo de Pesquisa	59
--	----

LISTA DE TABELAS

Tabela 1 - Escala de Coma de Glasgow	55
Tabela 2 - Escala EMU.....	56
Tabela 3 - Avaliação dos algoritmos	70

LISTA DE ABREVIATURAS E SIGLAS

- AM - Aprendizado de Máquina
- APAS - *Ariel Performance Analysis System*
- ASIA - *American Spinal Injury Association*
- AUC - Área sob a Curva ROC
- AVC - Acidente Vascular Cerebral
- AVD's - Atividades de Vida Diária
- AVE - Acidente Vascular Encefálico
- Big Data - Grande Volumes de Dados
- CCDSSs - Sistemas Computadorizados de Apoio à Decisão Clínica
- CIF - Classificação Internacional de Funcionalidade, Incapacidade e Saúde
- CIFAR - *Canadian Institute for Advanced Research*
- CLDR - *Center for Large Data Research and Data Sharing in Rehabilitation*
- COFFITO - Conselho Federal de Fisioterapia e Terapia Ocupacional
- COVID-19 - Síndrome Respiratória Aguda Grave do Coronavírus 2
- CREFITO - Conselho Estadual de Fisioterapia e Terapia Ocupacional
- CSV – *Comma Separated Values*
- DASH - Data and Specimen Hub
- DATAMED - *Biomedical and Healthcare Data Discovery Index Ecosystem*
- DM - Diabetes Mellitus
- DP - Desvio Padrão
- DPOC - Doença Pulmonar Obstrutiva Crônica
- ECG - Eletrocardiograma
- ECG - Escala de Coma de Glasgow
- EEG - Eletroencefalografia
- EENM - Estimulação Elétrica Neuromuscular
- EMU - Escala de Mobilidade em Unidade de Terapia Intensiva
- FN - *False Negative*
- FNR - *False Negative Rate*
- FP - *False Positive*
- FPR - *False Positive Rate*
- GEP/HU/UFSC - Gerência de Ensino e Pesquisa do Hospital Universitário da Universidade Federal de Santa Catarina

HU/UFSC - Hospital Universitário da Universidade Federal de Santa Catarina

IA - Inteligência Artificial

IAM - Infarto Agudo do Miocárdio

IMC - Índice de Massa Corporal

LANSS - *Leeds Assessment of Neuropathic Symptoms and Signs Pain Scale*

MIF - Medida de Independência Funcional

MIMIC - *Medical Information Mart for Intensive Care*

ML - *Machine Learning*

MRC - *Medical Research Council*

NDS - *Neuropathy Disability Score*

NICHHD - *Eunice Kennedy Shriver National Institute of Child Health and Human Development*

NIH - *National Institute of Health*

OESIL - *Osservatorio Epidemiológico Sulla Síncope Nel Lazio*

OMS - Organização Mundial de Saúde

OPS - Organização Panamericana de Saúde

PUBMED - Serviço da *United State National Library of Medicine*

RM - Ressonância Magnética

RM1 - Resistência Máxima

ROC - Curva do Operador de Receptor

SFSR - *Saint Francis Syncope Rule*

TCUD - Termo de Compromisso de Utilização de Dados

TNR - *True Negative Rate*

TP - *True Positive*

TPR - *True Positive Rate*

TTM - *Targeted Temperature Management*

TVM-6 -> Teste de Velocidade de Marcha de seis minutos

UFSC - Universidade Federal de Santa Catarina

UTI - Unidade de Terapia Intensiva

VMI - Ventilação Mecânica Invasiva

VNI - Ventilação Mecânica Não-Invasiva

XLXS - Tipo de arquivo do Microsoft Excel

SUMÁRIO

1	INTRODUÇÃO	15
1.1	OBJETIVOS.....	20
2	REVISÃO DE LITERATURA	21
2.1	MOBILIDADE FÍSICA NO AMBIENTE HOSPITALAR.....	21
2.1.1	Envelhecimento e Fragilidade	21
2.1.2	Efeitos da Imobilidade	23
2.1.3	Força, Resistência e Marcha.....	25
2.1.4	Ambiente Hospitalar	27
2.1.5	Declínio Funcional.....	28
2.2	Fisioterapia Hospitalar	30
2.2.1	Histórico	30
2.2.2	Definições e Regulamentações	30
2.2.3	Testes e Protocolos.....	32
2.2.4	Recursos Fisioterapêuticos	33
2.2.5	Reabilitação Hospitalar	35
2.3	Aprendizado de Máquina em Saúde.....	38
2.3.1	Inteligência Artificial e Ciência de Dados	38
2.3.2	Aprendizado de Máquina	40
2.3.3	Redes Neurais Artificiais	44
3	MÉTODOS.....	51
3.1	Tipo de Estudo.....	51
3.2	Natureza do Estudo	51
3.3	Local do Estudo.....	51
3.4	Base de Dados	52
3.5	População e Amostra.....	53
3.6	atributos de seleção e identificação	53

3.7	Considerações Éticas	58
3.8	Protocolo do Estudo	59
3.8.1	Etapa 1 - Pesquisa Bibliográfica	59
3.8.2	Etapa 2 - Pré-processamento do Conjunto de Dados.....	60
3.8.3	Etapa 3 - Criação e Desenvolvimento do Modelo.....	61
3.8.4	Etapa 4 - Resultados do Modelo.....	62
3.9	Métricas de validação do modelo	62
4	RESULTADOS.....	64
4.1	Perfil dos Pacientes	64
4.2	Aplicação do Modelo	66
5	DISCUSSÃO	71
6	CONSIDERAÇÕES FINAIS.....	74
7	REFERÊNCIAS	75
8	APÊNDICES.....	88
8.1	Apêndice 1 - Termo de Compromisso de Utilização de Dados (TCUD).....	88
8.2	Apêndice 2 – Parecer Consubstanciado do CEP	89
8.3	Apêndice 3 – Carta de Anuência	94

1 INTRODUÇÃO

A perda de mobilidade é um fenômeno comum naqueles pacientes restritos ao leito. A diminuição da atividade física e o repouso contribuem para piora da recuperação do paciente, associado ao aumento dos riscos de doenças. Segundo Cao et al. (2020), um estudo com idosos hospitalizados demonstrou que a baixa mobilidade e o repouso no leito eram comuns e estavam associados a resultados adversos, como declínio na capacidade de realizar atividades da vida diária, morte e institucionalização. Um estudo italiano de Pasina et al. (2018) concluiu que estar acamado é um fator de risco para mortalidade em curto prazo de pacientes não oncológicos. Já com relação aos pacientes em condição pós-cirúrgica, Scarborough et al. (2015) observaram que pessoas dependentes geralmente tinham maiores chances de morte, comparadas com aquelas que eram funcionalmente independentes, incluindo os casos de cirurgia bariátrica, em que os acamados tiveram 4,59 vezes mais chance de complicações, maior tempo de internação, reinternação e mortalidade.

Na China, segundo a pesquisa de Cao et al. (2020), o número de pessoas idosas com incapacidade física total ou parcial, atingiu mais de 40 milhões, e a imobilidade é comum neste grupo. Foram avaliadas as internações durante 90 dias, com 1.114 pacientes e constatou-se que a média de idade dos pacientes era de 69 anos, com uma taxa de mortalidade de 4,7%, sendo a mediana do tempo acamado de nove dias e do tempo de internação de 12 dias. Percebe-se que o perfil da enfermagem de um hospital geral é abrigar pacientes idosos. Nos idosos hospitalizados, o declínio funcional pode ocorrer em questão de dias, apresentando resultado devastador na independência física, nas quais a fisiologia do envelhecimento associada ao repouso no leito ou baixa mobilidade, provocam mudanças estruturais irreversíveis para realização das atividades de vida diária, após a alta hospitalar (CAO et al., 2020).

No contexto de baixa mobilidade funcional, a fisioterapia é a responsável pela avaliação e conduta, com o objetivo de prevenir, manter ou melhorar a mobilidade física. O fisioterapeuta atua nas mais diversas desordens sejam de origem neurológica, respiratória, motora, cardíaca e hemodinâmica. Segundo o Conselho Federal de Fisioterapia e Terapia Ocupacional (2021), “a Fisioterapia é uma ciência da Saúde que estuda, previne e trata os distúrbios cinéticos funcionais intercorrentes em órgãos e sistemas do corpo humano, gerados por alterações genéticas, por traumas e por doenças adquiridas. Fundamenta suas ações em mecanismos terapêuticos próprios, sistematizados pelos estudos da Biologia, das ciências

morfológicas, das ciências fisiológicas, das patologias, da bioquímica, da biofísica, da biomecânica, da cinesia, da sinergia funcional, e da cinesia patologia de órgãos e sistemas do corpo humano e as disciplinas comportamentais e sociais”. Já o Fisioterapeuta “é o profissional de saúde, com formação acadêmica superior, habilitado à construção do diagnóstico dos distúrbios cinéticos funcionais (Diagnóstico Cinesiológico Funcional), a prescrição das condutas fisioterapêuticas, a sua ordenação e indução no paciente bem como, o acompanhamento da evolução do quadro clínico funcional e as condições para alta do serviço” (COFFITO, 2021). E por fim é atividade de saúde, regulamentada pelo Decreto-Lei 938/69, Lei 6.316/75, Resoluções do COFFITO, Decreto 9.640/84, Lei 8.856/94. (CREFITO-10, 2021).

No meio acadêmico é observada uma ênfase nas discussões sobre técnicas, protocolos e perfis de pacientes, como benefício da mobilização precoce, no atendimento da fisioterapia, delimitado às Unidades de Terapia Intensiva. Porém, o profissional fisioterapeuta também atua de forma eficaz e imprescindível nas enfermarias hospitalares. Nelas, colabora para minimizar os efeitos deletérios que o tempo prolongado de internação hospitalar provoca nos pacientes, otimizando o tratamento global, repercutindo em um menor tempo de internação, reduzindo a mortalidade e proporcionando uma melhor qualidade de vida após alta hospitalar (CONCEIÇÃO et al., 2014). Nesse sentido, um modelo que possa fornecer um prognóstico amparado em inteligência artificial, no contexto de mobilidade no ambiente hospitalar, seria de grande valia para a área.

Na última década houve um crescimento substancial em pesquisa de análise preditiva, isto é, na capacidade de prever ocorrências, utilizadas em mídias sociais, na indústria, no comércio, entre outras. Essa tendência também se manifestou na área da saúde e a análise de dados médicos por ferramentas de inteligência artificial, para a melhor tomada de decisão, se intensificaram, incluindo o auxílio no processamento de exames, imagens como de tomografia computadorizada e na pesquisa, a funcionalidade com base nos valores de escalas aplicáveis (THACURIAH, DIRKS, KEITA, 2017).

Para a realização da análise preditiva, existem várias técnicas como o aprendizado de máquina, que é a aplicação de algoritmos nos sistemas computacionais que se aprimoram automaticamente com a experiência (MITCHELL, 1997). É uma forma de inteligência artificial que permite que os softwares se tornem mais precisos na previsão de resultados sem serem explicitamente programados (MUNERA et al., 2017). Os métodos de aprendizado de

máquina importam dados históricos e os comparam com os dados atuais para prever o que acontecerá no futuro. Com a atualização de cada dado novo, de fontes determinadas, a máquina aprende como ser mais precisa na previsão (DELOUILLE et al, 2018).

Os algoritmos de aprendizagem de máquina são eficazes, pois através deles ocorre um processo automatizado de busca por funções matemáticas que formulem um modelo, baseados na análise do treinamento de dados com classes já rotuladas. Dentre os mais utilizados para problemas de classificação cita-se a rede neural artificial, máquina de vetor de suporte (SMV), K-Vizinhos mais próximos (KNN) e Randon Forest (HAN, PEI, KAMBER, 2011).

Para Tack (2019), a inteligência artificial pode melhorar os cuidados de saúde por meio do avanço da prestação de cuidados, tomada de decisões e envolvimento do paciente. Ela configura o desenvolvimento de sistemas de computador para resolver problemas associados à inteligência humana. O Aprendizado de Máquina é uma forma de inteligência artificial onde algoritmos fazem previsões para interpretar dados e aprender sem instruções programadas. Existem duas formas principais: supervisionado e não supervisionado. O Aprendizado de Máquina supervisionado ocorre onde os algoritmos recebem dados de treinamento, que são rotulados. O modelo, então é treinado com esses dados antes de ser testado com dados não rotulados, e fornecer uma saída de interpretação. Quando a saída é discreta, chama-se de “classificação”, isto é, a previsão de um rótulo. Já se a saída for contínua, chama-se de “regressão”, onde se faz a previsão de uma quantidade. O Aprendizado de Máquina não supervisionado é usado para identificar padrões sem treinamento, por exemplo, na análise de cluster, onde os dados são agrupados por características.

Em medicina física e reabilitação, o uso de big data e ciências de dados mostram implicações importantes para a pesquisa e prática, assim como desafios na construção da expansão dessa nova cultura de pesquisa. Para tanto, o padrão misto, envolvendo pesquisas quantitativas e qualitativas são poderosas na área da saúde. Nesse contexto, Ottenbacker, Graham e Fisher (2019) citam o *Mobilize Center*, que se concentra no estudo da atividade física em três áreas de pesquisa, que são o gerenciamento em paralisia cerebral, recuperação da marcha e monitoramento do controle de peso. Os autores também destacam a importância da criação de conjuntos de dados na tomada de decisão em saúde, citando os repositórios de

banco de dados como o DASH-NICHD¹, CLDR² e DATAMED³, que estão ampliando e melhorando o valor das pesquisas.

No cenário atual, observa-se o desenvolvimento de tecnologias médicas, incluindo variadas aplicações, criadas a partir de realidade virtual, inteligência artificial e Aprendizado de Máquina. No campo da Fisioterapia, a demanda pela reabilitação em domicílio está aumentando, pois o ambiente é geralmente favorável à recuperação. Neste enquadramento, Sachi et al. (2019) propõem um aplicativo que registra os exercícios de fisioterapia, fornecendo orientações personalizadas, baseadas no desempenho do paciente, destacando a aplicação da biblioteca *Open Pose Library*⁴ de código aberto, para detectar posturas incluindo gestos, lançamentos, atividades esportivas, entre outras. Assim, processa imagens e vídeos, em tempo real, avaliando o ângulo entre as articulações e guiando o paciente na realização da reabilitação domiciliar.

Segundo Rodeghero e Cook (2014), em estudos como de Fritz et al. (2012), na função da Fisioterapia no tratamento da dor lombar, empregaram a extração de dados de bancos de dados existentes, tais como na pesquisa de Cook, Cook e Worrell (2008), na qual utilizaram uma amostra com 100 mil registros de indivíduos hospitalizados com dor lombar, tratados com terapia manual, o que favoreceu os processos de compreensão da lesão associados as descobertas clínicas muito valiosas. Além disso, a análise do conjunto de dados pode mostrar informações como tipo de tratamento, tempo de atendimento, prognóstico, satisfação, etc. O uso dessa grande quantidade de dados também tem influência na gestão da saúde, adaptando padrões e estratégias na tomada de decisão. A análise e interpretação dos volumes de dados devem provocar reformulação na prestação de serviço, incluindo na área da Fisioterapia, contribuindo para a compreensão de quais as melhores formas de atenção, individualizada. Por isso, chama-se a atenção para a construção de banco de dados, a partir da coleta qualificada, pelo seu enorme potencial de geração de conhecimento.

Um dos problemas em reabilitação é a adesão ao tratamento, e nesse sentido Burns et al. (2018) utilizaram sensores vestíveis para detectar a adesão aos exercícios propostos. Foram testadas 20 pessoas, que realizaram o protocolo de reabilitação do manguito rotador, enquanto usavam o Apple iWatch. Vários métodos de Aprendizado de Máquina foram utilizados neste

¹ <https://dash.nichd.nih.gov/>

² <http://cldr.unicode.org/>

³ <https://datamed.org/index.php>

⁴ <https://analyticsindiamag.com/guide-to-openpose-for-real-time-human-pose-estimation/>

estudo e a precisão de classificação de uma rede neural foi de 99,4%. Concluiu-se nesse caso, o modelo supervisionado tem grande potencial de mensuração e ajuda na tomada de decisão.

Ainda abordando o problema de adesão e acompanhamento, Lião, Vakanski e Xian (2020) afirmam que atualmente faltam sistemas que monitorem e avaliem o desempenho do paciente, durante a reabilitação. Embora existam ferramentas com interface de realidade virtual, jogos e assistência robótica, os autores propõem uma estrutura de avaliação da recuperação fisioterapêutica, com métricas de quantificação e codificação da qualidade dos movimentos, baseados nos dados de mobilidade das articulações corporais, através de redes neurais. Os autores complementam que a pesquisa tem potencial avaliativo na realização dos exercícios de reabilitação, através da utilização de *Machine Learning*.

Na pesquisa de Kruse et al. (2018) com objetivo de predição de baixa mobilidade e mortalidade em idosos belgas por meio da avaliação da sarcopenia, utilizando os princípios de Aprendizado de Máquina, concluiu-se que a mortalidade pode ser prevista com boa precisão e que nesse caso, os escores séricos de 25-hidroxivitamina D e a densidade mineral óssea foram os preditores mais importantes.

Para Van Der Aalst (2016), atualmente, a ciência de dados faz uma conexão entre as áreas matemáticas e computacionais, incluindo estatística e mineração de dados como uma disciplina de grande destaque nas grandes organizações. Sua missão é transformar dados, em quantidades volumosas, em valor para as pessoas, organizações e sociedade. Nessa conjuntura novos desafios apareceram em termos de Big Data e na resolução de problemas.

Após a discussão dos temas a serem explorados na pesquisa, observa-se a sua relevância social, pois o desenvolvimento do uso da inteligência artificial nos serviços de saúde se faz importante para alcançar diagnósticos e prognósticos fisioterapêuticos mais acurados. Ela se notabiliza, pois a avaliação de modo manual pode ter custo elevado com recursos humanos, além de envolver processos que podem ser repetitivos e cansativos, sendo que a fadiga compromete a qualidade. Além disso, a execução de um programa pode gerar o resultado dezenas, centenas ou milhares de vezes mais rápido do que o mesmo procedimento feito de forma manual. E por fim nos possibilita armazenar dados, melhorar o conhecimento sobre o estado de saúde dos pacientes, colaborar no manejo da reabilitação e predição na avaliação física.

Entretanto, mesmo usando computadores para auxiliar em uma tarefa, a avaliação final deve ser do especialista na área da saúde. Um algoritmo pode servir para triagem e ordenação de prioridade de atendimento/tratamento.

O objeto de pesquisa visou avaliar a capacidade de locomoção independente dos pacientes que receberam atendimento fisioterapêutico, durante a internação hospitalar em unidade de clínica médica e cirúrgica do HU/UFSC, sendo para esse fim, utilizado um banco de dados histórico, com dados de Janeiro a Dezembro de 2020. A pergunta de pesquisa adotada é: O resultado das intervenções fisioterapêuticas na mobilidade funcional dos pacientes internados em enfermaria de um hospital universitário pode ser predito através de um modelo de Aprendizado de Máquina?

Por fim, deseja-se que a análise do conjunto de dados, usados para treinamento e teste de uma rede neural artificial, possa reafirmar a importância do serviço de fisioterapia no ambiente hospitalar, especificamente nas enfermarias das clínicas médicas e cirúrgicas.

1.1 OBJETIVOS

- Desenvolver uma modelagem de Aprendizado de Máquina para predição da mobilidade funcional dos pacientes internados em enfermarias, que recebem atendimento fisioterapêutico.
- Avaliar o modelo classificador de redes neurais no conjunto de dados de teste.

2 REVISÃO DE LITERATURA

De modo a alinhar a sustentação teórica da dissertação, contemplando áreas distintas, a presente revisão de literatura está organizada em três seções: Mobilidade física no ambiente hospitalar, Fisioterapia Hospitalar e Aprendizado de Máquina em Saúde.

2.1 MOBILIDADE FÍSICA NO AMBIENTE HOSPITALAR

2.1.1 Envelhecimento e Fragilidade

Nas clínicas de enfermagem hospitalar predomina o internamento de pacientes idosos. Nos idosos hospitalizados, o declínio funcional pode ocorrer em questão de dias, apresentando resultado devastador na independência física, nas quais a fisiologia do próprio envelhecimento associada ao repouso no leito ou baixa mobilidade, provocam mudanças estruturais irreversíveis, repercutindo na realização das atividades de vida diária (CAO et al., 2020).

Durante o processo de envelhecimento ocorrem diversas alterações corporais como no sistema nervoso central afetando o controle postural e equilíbrio. Nele pode haver comprometimento do sistema neuromotor, que se traduz na diminuição gradual da força muscular; na capacidade sensório-perceptiva, através da perda da comunicação e autonomia; no declínio funcional, pela incapacidade de realizar tarefas cotidianas; e no declínio cognitivo, com alterações da capacidade julgamento e habilidades viso-espaciais. Nesse contexto chama-se a atenção para a repercussão do declínio funcional, pois as limitações físicas e cognitivas, incluindo mobilidade e deslocamento são devastadoras. Salienta-se o equilíbrio como uma habilidade essencial de estabilidade e segurança nas atividades cotidianas, indispensável para um envelhecimento saudável (MIRANDA, 2014).

O envelhecimento gera modificações estruturais e funcionais que afetam a normalidade no processamento central do movimento, no controle postural e na sensibilidade e motricidade. À vista disso, o equilíbrio, importantíssimo para uma boa funcionalidade, é composto pela integração de informações proprioceptivas, sensoriais, visuais, neuromusculares e vestibulares. A alteração desse complexo sistema causa distúrbios de marcha repetitivos e a queda é o desfecho mais comum, frequente e limitante. As recidivas de quedas geram insegurança e é um parâmetro destacado para mortalidade em idosos. Embora

muitos tratem esses distúrbios com medicamentos, o tratamento através do exercício físico, psicomotor, que estimula fibras de contração rápida, é eficiente (ANJOS et al., 2015).

Santos e Silva Neto (2017) citam que para que o processo de envelhecimento seja mais saudável, a atividade física é fundamental, tanto pelos aspectos biológicos, psicológicos e sociais, como pela sensação de bem-estar proporcionado. Os autores ressaltam a melhora da mobilidade física relacionada à qualidade e expectativa de vida. O treinamento resistido atua em inibir os efeitos do envelhecimento como a perda de força e equilíbrio.

Como verificado no ambiente hospitalar de uma unidade de enfermaria, a média de idade de pacientes atendidos pelo serviço de Fisioterapia está próxima dos 60 anos e o contexto do envelhecimento causa algumas modificações que segundo Muller, Tavares e Schneider (2016) levam a limitação progressiva, redução do desempenho de habilidades motoras e dificuldade de adaptação a novos cenários. Ainda, os autores denominam o processo normal de envelhecimento de senescência, enquanto o processo provocado por associação com doenças chama-se de senilidade.

Para Lang, Michel, Zekry (2009) a fragilidade é comumente percebida no ambiente hospitalar, sendo caracterizada como uma síndrome multifatorial, combinada com a diminuição da reserva física, fisiológica e cognitiva, associada a condições como perda de peso não intencional, fraqueza muscular, fadiga, desnutrição, comprometimento da marcha e vulnerabilidade a traumas e infecções. Ainda, Fried e Walston (2009) incluem os resultados adversos, como quedas, dependência, incapacidade, maiores tempo de internamento e mortalidade, nas pessoas classificadas como frágeis.

Como proposta de avaliação da síndrome da fragilidade clínica, Fried et al. (2001) a apresentou para acompanhamento e previsão de sobrevida. No estudo foi definida a presença de três critérios determinando o aparecimento da síndrome, incluindo a perda de 5% do peso corporal no último ano, exaustão referida, fraqueza muscular, lentificação da marcha e redução da atividade física. Com o mesmo objetivo, Rockwood et al. (2005), propuseram a escala clínica de fragilidade, abordando os domínios da cognição, motivação, condição motora, equilíbrio, atividades de vida diária, condição nutricional e social e morbidades.

Para Adler e Malone (2012), a fragilidade tem forte relação com a funcionalidade, podendo observá-la na avaliação da maioria dos escores de fragilidade. Nesse contexto, em Zisberg et al. (2015) observa-se a cultura da imobilidade no leito, associada às restrições pelos dispositivos, que colaboram para o declínio imediato e mortalidade após alta hospitalar.

Segundo Bagshaw et al (2015), a fragilidade é um importante preditor para morbidade, pois naqueles pacientes que sobrevivem à doença crítica houve uma redução de 20% nas chances de manter-se de forma independente no domicílio comparados aos não críticos ou população geral.

2.1.2 Efeitos da Imobilidade

No estudo de Allen, Glasziou e Del Mar (1999) há referência do início da cultura do repouso absoluto até metade do século XX, em que os estudos sobre os efeitos da mobilidade e impacto nos sistemas corporais iniciaram e que poderiam evitar eventos adversos, incluindo a mortalidade.

Segundo Abate (2013) o aumento da longevidade culminou no aparecimento de doenças crônicas e agudas incapacitantes. A imobilidade é considerada uma síndrome que leva a supressão dos movimentos articulares, podendo ser de origem neurológica ou musculoesquelética. A síndrome do imobilismo compromete o sistema osteomuscular, levando a limitações funcionais, observadas na postura, transferência, movimento no leito e cadeira de rodas, dificultando atividades básicas e instrumentais da vida diária. No momento em que a capacidade funcional se reduz continuamente, surgem sinais como a trombose venosa profunda, sintomas respiratórios, nervosos, gastrointestinais, entre outros. E nesse sentido, tem se dado maior atenção aos efeitos deletérios do tempo prolongado no leito e destacado os benefícios da atividade física e exercícios.

Quanto à fisiopatologia, na imobilização prolongada, percebe-se proliferação do tecido conectivo fibroso no espaço articular, adesões sinoviais, aderência no tecido cartilaginoso, atrofia e bloqueio articular, além do processo inflamatório contínuo entre as cartilagens, desorganização celular no músculo e fibras ligamentares, enfraquecimento na inserção de ligamento e reabsorção osteoclástica acelerada. Quanto à postura, na posição deitada a atividade muscular é mínima e a força da gravidade nos ossos e músculos de apoio é reduzida. Em uma semana de repouso perde-se de 10 a 15% da força e 50% em 3 a 5 semanas (ABATE 2013).

Fried et al. (2021) mencionam a sarcopenia como um dos mais importantes sinais clínicos, caracterizado pela redução da massa muscular, principalmente das fibras de contração rápida, sendo um achado importante nos pacientes frágeis, sendo de origem

multifatorial como nutrição inadequada, inatividade física e alteração hormonal. Os autores ainda destacam que a perda de força pode ser mais drástica do que a redução da massa muscular.

O estudo de Bednarik et al. (2005) concluiu que em indivíduos saudáveis, os músculos mostram redução de sarcômeros em até 4 horas após a imobilização. Após uma semana a força muscular pode chegar a diminuição de 5 a 10%, com uma perda de 1 a 1,3% de perda diária na força muscular total. Salienta-se que essa redução ocorre em pacientes saudáveis, sendo que em pacientes graves a situação potencializa-se pelo acelerado catabolismo.

Na pesquisa de Lipshutz e Gropper (2013) observando o repouso corporal foi percebido que os músculos são ativados por curtos períodos de tempo e cargas menores, comparados às situações cotidianas. Essa redução do uso ocasiona fraqueza muscular generalizada, sujeitando os pacientes a quadros de sepse, inflamação sistêmica e falência de múltiplos órgãos.

No paciente acamado pela doença crítica, Herridge et al (2003) citam a dor persistente, contraturas e fraqueza muscular como as principais queixas neuromusculares, colaborando para as limitações funcionais e piora da qualidade de vida.

Nos pacientes restritos ao leito hospitalar, a perda de mobilidade é um fenômeno comum. A diminuição da atividade e o repouso no leito contribuem para piora da recuperação do paciente associado ao aumento dos riscos à saúde. O estudo de Cao et al (2020), com idosos hospitalizados, demonstrou que a baixa mobilidade e o repouso no leito eram comuns e estavam associados a resultados adversos, como declínio na capacidade de realizar atividades da vida diária, morte e institucionalização. O trabalho italiano de Pasina et al. (2018) concluiu que estar acamado é um fator de risco para mortalidade em curto prazo de pacientes não oncológicos. Com relação aos pós-cirúrgicos, Scarborough et al. (2015) observaram que pacientes dependentes geralmente tinham maiores chances de morte, comparados com aqueles que eram funcionalmente independentes. O grupo dos pacientes acamados tinha 4,59 vezes mais chance de complicações, incluindo maior tempo de internação, mortalidade e reinternações.

Na pesquisa chinesa de Cao et al. (2020), o número de pessoas idosas com incapacidade física total ou parcial atingiu mais de 40 milhões, sendo a imobilidade comum neste grupo. Com relação às internações observadas durante 90 dias e com 1.114 pacientes, constatou-se que a média de idade dos pacientes foi de 69 anos, com uma taxa de mortalidade

de 4,7%, sendo a mediana do tempo acamado de 9 dias e do tempo de internação de 12 dias. Dados que mostram quão oneroso torna-se o cuidado com os pacientes mais dependentes.

2.1.3 Força, Resistência e Marcha.

Segundo Winkelmann (2007) os músculos são totalmente adaptáveis, apresentando ciclos contínuos de remodelação. Eles respondem rapidamente ao uso e desuso por meio de mudanças no diâmetro, comprimento, tipos de fibras contráteis e irrigação vascular. Topp et al. (2002) concluíram que indivíduos saudáveis que mantiveram repouso completo durante uma semana, apresentaram perda de 1,3 a 3% de perda de força muscular global.

Em indivíduos saudáveis, Garcia (2008) afirmou que a força muscular atinge o pico aos 30 anos e se mantém até os 50 anos, com pequeno declínio. Já Mijnders et al. (2015), comentam que nos idosos acima dos sessenta anos, ocorre redução significativa, aumentando o risco de sarcopenia em 60%. Ainda, Deschenes (2004) conclui que a cada década após os 50 anos, a força muscular é reduzida de 8 a 15%.

Para Bierbrauer et al. (2012) a falta de estímulo à musculatura esquelética causa mudança da conformação das suas fibras, ressaltando que a falta de ativação das fibras de contração rápida perde espessura, sofrendo necrose tecidual e substituição do tecido muscular por tecido adiposo e fibrose.

Segundo Pandharipande et al. (2013) um mecanismo central pode ser responsável pela fraqueza, além dos mecanismos periféricos. Nesse cenário, a fadiga é uma condição comum, associada a 70% dos sobreviventes da síndrome de desconforto respiratório agudo, associadas à ansiedade, depressão, dor e deficiências cognitivas.

Como forma de avaliação da força muscular, Fried et al. (2001) preconizam o teste de preensão palmar como a principal forma de determinação da fraqueza muscular, sendo positiva naqueles com valores abaixo de 20% do normal, a depender da massa corporal e gênero. Em hospitais, o teste de preensão palmar geralmente é substituído pelo escore do *Medical Research Council* (MRC), que possui validação científica, boa aplicabilidade e custo baixo.

Na discussão sobre resistência muscular, é inevitável a avaliação da postura, citada por Toledo (2010) como a representação do posicionamento dos segmentos corporais, uns em

relação aos outros e sua orientação no espaço. Para Ishizuka et al (2008), a orientação postural é vista como a capacidade de manter uma relação adequada entre o corpo e o ambiente durante determinada tarefa, enquanto a estabilidade postural é a capacidade de manter o corpo dentro dos limites da base de sustentação. Soldera (2013) complementa a importância dos sistemas somatossensorial e vestibular no controle dos músculos do pescoço, do reflexo vestibulo coclear, na interação das informações visuais e do reflexo vestibulo espinhal, na estabilização corporal de tronco e membros.

Para Perry, Burnfield e Cabico (2010) a dificuldade de locomoção é uma queixa comum nos hospitais e clínicas de reabilitação, e esses pacientes demonstram um padrão de marcha associando movimentos normais com movimento compensatórios, aumentando o gasto energético e comprometendo a eficiência da marcha.

No contexto da locomoção expõe-se a marcha, o meio natural de deslocamento do ser humano, que envolve a interação dos sistemas sensoriais, cognitivos, cardiorrespiratório, musculoesquelético e nervoso. De acordo com Shumway & Woollacott (2007) o ciclo de marcha normal é dividido em fase de apoio, representando 60% do ciclo e a fase de balanço, com os 40% restantes. Para Lundy-Ekman (2007), a tomada de decisão para início da fase da marcha se dá no lobo frontal, seguindo a ativação de áreas do planejamento motor, circuitos descendentes, inter-neurônios espinhais e neurônios motores inferiores, que levam a informação para contração muscular, sendo todo o processo ajustado pelas informações sensoriais.

Martinez et al. (2016) correlacionam a população idosa com a capacidade de marcha no ambiente hospitalar, referindo que 19,3% dos pacientes acima de 60 anos hospitalizados, relatam quedas. Partindo disso, existe a necessidade de testes físicos, mas que não criem um alto risco ao doente. Dentre os testes, citam o de velocidade de marcha de seis metros (TVM6) que avalia a mobilidade rapidamente, tem baixo custo e boa reprodutibilidade em idosos, fornecendo risco para quedas e possíveis intervenções específicas de tratamento.

Ainda na discussão sobre limitações nas atividades de vida diária, Nunes et al. (2016) destacam as quedas e a incidência de fraturas. Segundo os autores, forma-se o ciclo com redução das atividades, menor uso da musculatura, redução nos níveis de força, alteração da funcionalidade específica e global, ocasionando as limitações funcionais. Nesse ambiente, define-se a capacidade funcional como a habilidade em executar tarefas, naqueles com as faculdades mentais íntegras. Uma variável importante da capacidade funcional é o equilíbrio

corporal, preditor de quedas em idosos, que pode ser dinâmico, referente à manutenção da postura durante o desempenho de uma habilidade motora, ou estático, quando se mantém o corpo com um mínimo de oscilação.

2.1.4 Ambiente Hospitalar

O desenvolvimento do declínio funcional em indivíduos hospitalizados, segundo Chang et al. (2012) é afetado por doenças como a hipertensão arterial sistêmica, diabetes mellitus, doença renal crônica e doenças vasculares.

Para Fhon (2013), as restrições no ambiente hospitalar causam redução da marcha do paciente, vindo deteriorá-la devido às alterações, como encurtamento e diminuição da altura do passo, aumento da base de suporte, redução da velocidade da marcha, redução da extensão do joelho e quadril, aumento da fase de apoio e aumento do tempo na fase de duplo apoio. Esse perfil postural resulta em maior gasto de energia, sendo mais cansativo associado à diminuição da aceitação e adesão às atividades.

Quanto ao quadro delirante percebido no ambiente hospitalar, Canevelli et al. (2017) o descreveram como um distúrbio de atenção, cognição e excitabilidade, instalado de forma aguda, que ocorre entre 18 a 35% dos pacientes internados, aumentando o risco de fragilidade e risco de morte.

Um dos desafios no tratamento da baixa mobilidade intra e pós-hospitalar é a manutenção do paciente em atividade, pois segundo Braun et al. (2011) 20% dos sobreviventes de doenças críticas, morrem no primeiro ano após alta hospitalar.

No estudo de Camila et al (2017), após 6 meses de alta da UTI, os pacientes demonstraram redução da funcionalidade e força muscular, muitas vezes necessitam de cuidadores após o internamento.

Mazo et al. (2007) ressaltam o aumento do tempo de permanência hospitalar dos pacientes com a síndrome da fragilidade, elevando os custos, seja ele tanto em instituições públicas como privadas.

O trabalho de Santos et al. (2016) destaca que os pacientes oriundos da unidade de terapia intensiva, apresentam frequentemente fraqueza muscular, demonstrada por atrofia e redução da capacidade contrátil do músculo quadríceps, que tem grande importância no

ortostatismo e marcha. Neste enquadramento, observa-se que a disfunção física pode persistir por mais tempo do que a fraqueza muscular e é detectada por meio de testes funcionais.

Segundo Needham et al. (2010), uma condição no paciente com longo tempo de internação, principalmente em unidade de terapia intensiva é o desenvolvimento de polineuropatia, caracterizada pelo comprometimento axonal sensitivo motor simétrico e distal, que afeta os músculos dos membros e tronco, incluindo os músculos respiratórios, sobressaindo a atrofia dos filamentos grossos de miosina na estrutura muscular.

Durante a internação é observada a caquexia que para Okoshi et al. (2013) é comum nos pacientes idosos internados em enfermarias, diagnosticados com perda de peso maior que 6% do peso habitual na ausência de outras doenças, envolvendo diminuição da ingestão alimentar, distúrbios no trato gastrointestinal, reações imunológicas e neuro-hormonais, e alterações catabólicas. Segundo Curtis et al. (2005), a condição está relacionada a um baixo índice de massa corporal (IMC), sendo que valores baixos se associam ao aumento da mortalidade.

No ambiente hospitalar depara-se com uma infinidade de doenças e Shumway & Woollacott (2007) afirmam que lesões neurológicas alteram a realimentação intrínseca, influenciando no planejamento e execução da estratégia motora, como por exemplo, após um acidente vascular encefálico, a funcionalidade da marcha pode ser alterada com as características de flexão plantar excessiva e com inversão, extensão excessiva do joelho e flexão inadequada do joelho. Gillen e Burkhardt (2004) complementam que as pessoas que apresentam hemiparesia têm menor comprometimento motor do mesmo lado da lesão e conseguem compensar os déficits, porém mesmo assim influenciam negativamente no padrão normal da marcha, principalmente nas funções do tornozelo e pé. Nesse contexto, a National Stroke Foundation (2010) observou que aproximadamente 70% dos indivíduos apresentam algum nível de perda de força muscular em membro superior e inferior após o episódio do acidente vascular encefálico.

2.1.5 Declínio Funcional

Para a OPS/OMS (2003), a funcionalidade é definida pela CIF (Classificação Internacional de Funcionalidade, Incapacidade e Saúde) como um termo que envolve a experiência humana relacionada à interação positiva entre as funções e estruturas corporais,

atividades e participação, com as condições de saúde e os fatores ambientais e pessoais. Já a incapacidade decorre da interação negativa entre os problemas nas funções e estruturas corporais, restrições à participação, limitações das atividades, com as condições de saúde e os fatores ambientais e pessoais.

Perera et al. (2016) estudando o declínio funcional, consideraram a velocidade da marcha como um importante preditor para o risco de mortalidade. Além disso, Fhon et al (2013), associam a perda de força muscular e redução da velocidade de marcha, a quedas da própria altura. O uso de diferentes medicamentos como diuréticos e betabloqueadores, quadros de delirium e déficits de cognição aumentam os incidentes de quedas, e as lesões decorrentes de queda são a sexta causa de morte entre os idosos.

Em um estudo longitudinal de Herridge et al (2011) que avaliou pacientes após 5 anos após alta hospitalar por síndrome do desconforto respiratório agudo, demonstrou limitação ao exercício, sequelas físicas e psicológicas e altos gastos em serviço de saúde.

Ding et al. (2020) estudaram uma população com 36.547 pessoas com diagnóstico primário de demência internados em 2013 e 2018, em 29 centros de cuidados paliativos. Os autores constataram que a maioria relatou baixos níveis de sofrimento, porém com altos níveis de dependência e baixa funcionalidade. As pessoas com demências requerem maior assistência nas tarefas de vida diária do que outros grupos com diferentes diagnósticos. Notou-se que são propensos a serem internados em instituições hospitalares e que a carga emocional e física enfrentada por familiares e cuidadores, é grande com a deterioração cognitiva, comunicativa e funcional.

Segundo Hermans e Van Den Berghe et al. (2015,) atualmente a condução da terapêutica do doente crítico contraindica o repouso prolongado, pois os efeitos da imobilidade, como atrofia e alteração das fibras musculares são potencializados. A doença de base por si só causa processo inflamatório, que a imobilidade intensiva para o surgimento de abrangência sistêmica.

2.2 Fisioterapia Hospitalar

2.2.1 Histórico

Historicamente, a Fisioterapia surge com a raça humana quando se tenta reduzir uma dor friccionando o local, modificando-se ao longo do tempo, através das técnicas de exercícios terapêuticos. A profissão originou-se no século XX, destacando-se pelas duas guerras mundiais, no qual o grande número de lesões e ferimentos graves necessitava de uma abordagem de reabilitação. Inicialmente executada por voluntários, a Fisioterapia acompanhou as grandes mudanças e transformações do século XX. No Brasil, a Fisioterapia originou-se na Santa Casa de Misericórdia de São Paulo, em 1929, mas somente no ano de 1951, foi criado o primeiro curso técnico para formação de fisioterapeutas. Em 1959 foi criada a Associação Brasileira de Fisioterapeutas e somente no dia 13 de outubro de 1969, a profissão adquiriu seus direitos, por meio do Decreto-lei nº 938/69 (CREFITO-3, 2021).

Através do estudo descritivo bibliográfico e documental de Carvalho e Oliveira (2016) destacou-se que a fisioterapia teve origem como ocupação técnica, entrelaçada à medicina.

A profissão está amparada pela legislação que regulamenta a atividade de Fisioterapia no decreto-lei, n. 938 de 13 de outubro de 1969, que provê sobre as profissões de Fisioterapeuta e Terapeuta Ocupacional. Destacando o Art. 2º, no qual o fisioterapeuta e o terapeuta ocupacional, diplomados por escolas e cursos reconhecidos, são profissionais de nível superior. O Art. 3º afirma ser atividade privativa do fisioterapeuta, executar métodos e técnicas fisioterapêuticas com a finalidade de restaurar, desenvolver e conservar a capacidade física do paciente (COFFITO, 2021).

2.2.2 Definições e Regulamentações

Segundo o Conselho Federal de Fisioterapia e Terapia Ocupacional (COFFITO) “a Fisioterapia é uma ciência da Saúde que estuda, previne e trata os distúrbios cinéticos funcionais intercorrentes em órgãos e sistemas do corpo humano, gerados por alterações genéticas, por traumas e por doenças adquiridas. Fundamenta suas ações em mecanismos terapêuticos próprios, sistematizados pelos estudos da Biologia, das ciências morfológicas, das ciências fisiológicas, das patologias, da bioquímica, da biofísica, da biomecânica, da cinesia, da sinergia funcional, e da cinesia patologia de órgãos e sistemas do corpo humano e as disciplinas comportamentais e sociais”. Já o Fisioterapeuta “é o profissional de saúde, com

formação acadêmica superior, habilitado à construção do diagnóstico dos distúrbios cinéticos funcionais (Diagnóstico Cinesiológico Funcional), a prescrição das condutas fisioterapêuticas, a sua ordenação e indução no paciente bem como, o acompanhamento da evolução do quadro clínico funcional e as condições para alta do serviço”. E por fim é atividade de saúde, regulamentada pelo Decreto-Lei 938/69, Lei 6.316/75, Resoluções do COFFITO, Decreto 9.640/84, Lei 8.856/94. (CREFITO-10, 2021).

Perera et al. (2016) caracterizam o fisioterapeuta como aquele que visa a recuperação do doente e preservação da funcionalidade através de recursos terapêuticos, guiado pelo movimento humano, utilizando os exercícios como forma de minimizar efeitos deletérios e maximizar a resposta motora.

Para Barbieiri e Zaccagni (2013), o fisioterapeuta preconiza a reabilitação motora, e nessa acepção têm-se as definições do trabalho de força muscular, definida como a máxima tensão que o músculo pode produzir, ou a máxima carga que possa suportar. Já a resistência, atualmente denominada *endurance*, é a capacidade de o músculo manter contrações repetitivas por um determinado período de tempo. A partir desse momento, o processo de reabilitação envolve a reversão, manutenção ou ganho de força muscular e *endurance*.

Segundo a revisão de Ferreira et al. (2017) o fisioterapeuta ganha respaldo científico proporcionado pelos benefícios do tratamento fisioterapêutico, atuando em clínicas, ambulatorios, hospitais, na atenção básica, entre outros. Destaca-se a inserção do profissional em unidades hospitalares em virtude da mobilização precoce no doente crítico, sendo a melhor alternativa na prevenção de agravos do imobilismo. O público atendido pelo serviço de fisioterapia é plural e oriundo de todas as especialidades médicas, tanto agudas como crônicas. A recuperação rápida reduz o risco de infecções hospitalares, promove rotatividade e reduz custos.

Quanto à síndrome pós-terapia intensiva, Denehy et al. (2013), apontam vários fatores que colaboram para seu surgimento, sendo o fisioterapeuta o profissional que identifica alterações articulares, musculares e neurológicas e institui precocemente condutas para reduzir os prejuízos adquiridos na internação. Os autores ainda acrescentam que a presença do fisioterapeuta é fundamental na equipe multidisciplinar para a reabilitação dos pacientes internados, instituindo a mobilização precoce, como uma medida segura e viável e pode promover funcionalidade após a estadia hospitalar.

Para Siciliano, Schirinzi, Simoncini e Ricci (2019) historicamente conceituado como uma ferramenta útil no tratamento de doenças musculares, o exercício físico esbarra em contradições ao ser debatido quanto à atividade contrátil do músculo associada à piora progressiva de determinadas condições neurológicas, como nas distrofias. Nos indivíduos saudáveis, o exercício reconhecidamente melhora a força e resistência muscular e a função cardiopulmonar, neutralizando a sarcopenia, prevenindo a osteoporose e sobrepeso, interferindo na cognição e humor, isto é, os mecanismos reparadores e regenerativos não induzem ao dano muscular crônico.

2.2.3 Testes e Protocolos

Segundo Parry et al. (2015) o teste de força manual, pelo somatório da escala de força muscular do *Medical Research Council*, é uma ferramenta usada para o diagnóstico clínico da força muscular em pacientes internados. Os seis grupos musculares avaliados bilateralmente são: abdutores de ombro, flexores de cotovelo, extensores de punho, flexores de punho, flexores de quadril, extensores de joelho e dorsiflexores de tornozelo. Cada um desses grupos é classificado de 0 a 5, com um escore total de 60 pontos. Para a realização do teste, o examinador se posiciona para permitir a completa amplitude de movimento da articulação contra a gravidade. O movimento é demonstrado, e caso o paciente o realize deve-se colocar uma resistência manual ao movimento. A partir desse cenário, caso o grupamento não apresentar nenhuma contração tem-se 0, havendo contração a palpação tem-se 1, se ocorrer o movimento parcialmente, em pequena amplitude tem-se 2, caso consiga vencer a gravidade gradua-se como 3, tolerando alguma resistência é 4 e conseguindo vencer a resistência completa tem-se 5 pontos. Salientando que essa medida é feita nos seis grupos musculares.

Barbieiri e Zaccagni (2013) citam a métrica de uma repetição máxima (1RM) para avaliar a força muscular, definida como a maior quantidade de carga que pode ser mobilizada de uma só vez, sem compensações e em completa amplitude de movimento. A execução é fácil e pouco onerosa, havendo a necessidade de pesos ou halteres durante a avaliação, o que pode ser um complicador para avaliação hospitalar e pelo risco/benefício desta modalidade.

O dinamômetro manual ou *Hand Grip* é citado por Latorre-Roman et al. (2014) como uma ferramenta importante que avalia a força de preensão palmar, possuindo forte correlação entre capacidade pulmonar e qualidade de vida.

Após a avaliação e testagem hospitalar, tem-se a forma de caracterização da evolução do tratamento, e para tanto Morris et al. (2008) desenvolveram um protocolo de atendimento fisioterapêutico, baseado em quatro níveis. O nível I compreende o paciente inconsciente, sendo a terapêutica baseada em mobilização passiva, três vezes ao dia, com pelo menos cinco repetições para cada articulação e mudança de decúbito a cada duas horas. O nível II, no qual o paciente atende o terapeuta, realiza-se movimentos ativos, ativo-assistidos e sedestação à beira do leito, mantendo-se pelo menos 20 minutos na posição sentada, 3 vezes ao dia. No nível III o paciente realizava exercícios resistidos em sedestação e no nível IV ocorre o treinamento para a transferência do leito para cadeira, atividades de equilíbrio, descarga de peso e deambulação. Segundo os autores, durante a validação do protocolo não houve intercorrências, sendo classificado como seguro e eficaz.

O protocolo de Schweickert (2009), também é dividido em 4 níveis, para pacientes no leito sedado ou não responsivos, pacientes restritos ao leito, pacientes acordados e no último nível voltado para pacientes acordados com controle de tronco e força muscular em membros inferiores.

2.2.4 Recursos Fisioterapêuticos

Para Abate (2013), a fisioterapia dispõe de recursos para reverter às alterações que ocorrem na síndrome do imobilismo. A mobilização precoce reduz a incidência de fenômenos tromboembólicos, permitindo uma melhor oxigenação e nutrição dos órgãos internos. Hoje em dia, uma das funções mais importantes do fisioterapeuta é a retirada precoce do paciente do leito, prevenindo as doenças associadas ao repouso prolongado.

A fisioterapia possui um arsenal de métodos e técnicas e entre as mais eficazes têm-se o exercício terapêutico como afirmam Silva, Maynard e Cruz (2010), com o objetivo de melhorar a funcionalidade e reduzir incapacidades. O surgimento de fraqueza muscular é comum do doente crítico, acometendo de 30 a 60% daqueles internados em UTI. O imobilismo é uma das principais causas, tendo influência negativa em todos os sistemas corporais, ressaltando o sistema muscular, com perda de massa, *endurance* e força. Esses fatores contribuem para o aumento do tempo de permanência, risco de complicações e mortalidade.

O exercício terapêutico deve ser iniciado o mais rápido possível, sendo altamente recomendado durante o internamento hospitalar. Mesmo sedado, o paciente deve receber atenção e estímulo como a manutenção do posicionamento adequado no leito e a mobilização precoce. A cinesioterapia é segura e viável, e dependerá do nível de capacidade funcional avaliada diariamente, iniciando passivamente, até alcançar a modalidade resistida (SILVA, MAYNARD E CRUZ, 2010).

Para Schwartz e Andrasik (2003), o *biofeedback* é um recurso terapêutico no tratamento de problemas de saúde, iniciado por volta de 1950, nos Estados Unidos. Ele é definido como toda a informação que o indivíduo recebe, assimila e modifica seu comportamento. O *biofeedback* terapêutico revela os estados corporais como a atividade muscular, frequência cardíaca e sudorese. Segundo Basmajian (1989) ele faz com que o paciente ou terapeuta tenha a percepção e modifique suas respostas para melhorar a funcionalidade corporal.

Uma das formas de terapêutica no doente hospitalar citada por Adler e Malone (2012) é a estimulação elétrica neuromuscular (EENM), uma das formas intervenções possíveis naqueles pacientes acamados incapazes de realizar uma contração muscular. Ela é utilizada para manutenção da integridade das fibras musculares e manutenção da força muscular, pois contribui para o aumento da capacidade muscular oxidativa. Ela pode ser aplicada de forma isolada ou associada a um programa de exercícios, sendo indicada naqueles pacientes com MRC inferior a 3, em membros inferiores e igual ou superior a 3 para melhorar o desempenho em atividades como sentar e levantar.

Segundo Zisberg et al. (2015) outro instrumento de reabilitação amplamente usado na reabilitação hospitalar é o cicloergômetro, um aparelho que permite rotações cíclicas, podendo ser usado para exercícios passivos, ativos ou resistidos, para os membros superiores e inferiores. O uso passivo foi associado ao incremento da funcionalidade, aumento da força muscular e melhor estado funcional após alta hospitalar. Ainda Skinner et al. (2009) complementam que o cicloergômetro é útil para melhora da capacidade aeróbia em pacientes em recuperação da síndrome pós terapia intensiva, sendo indicada monitoração e prescrição do exercício pela variação da frequência cardíaca e escala de Borg. Os autores também preconizam a deambulação precoce, assim como a educação do paciente e família no quesito recuperação funcional.

A busca pela capacidade de ficar em pé é um dos grandes objetivos na reabilitação hospitalar e nesse sentido Rydingsward et al. (2016) preconizam a realização do ortostatismo, tanto ativo como passivo, indicado para pacientes com limitação em decorrência de fraqueza muscular, porém estáveis hemodinamicamente, pois a postura ereta promove alterações no fluxo cardiovascular. Do ponto de vista musculoesquelético, o ortostatismo produz um melhor alinhamento corporal, propiciando alongamento e fortalecimento de certos grupos musculares, prevenindo deformidades de membros inferiores e funcionalidade dos membros superiores.

E por fim, dentro da reabilitação, Behm et al. (2017), citam os exercícios pliométricos, compostos por movimentos explosivos, com fortes contrações musculares em altas velocidades, que buscam melhora da potência e aptidão cardiovascular. Como exemplo citam os exercícios de saltar, polichinelos e movimentos de tronco, porém é pouco recomendado no ambiente hospitalar.

2.2.5 Reabilitação Hospitalar

Segundo a revisão de Ferreira et al. (2017) em enfermaria hospitalar, o profissional fisioterapeuta ajuda a reduzir os efeitos deletérios que o tempo de internação provoca e a mobilização precoce é segura e efetiva para melhora da força muscular, resistência, funcionalidade e nível de consciência. O fisioterapeuta deve estimular a sedestação no leito e a beira leito, e orientar técnicas de reexpansão pulmonar. O autor observa o predomínio de técnicas e protocolos da fisioterapia em unidade de terapia intensiva, porém o profissional fisioterapeuta também atua de forma eficaz e imprescindível nas enfermarias hospitalares.

No atendimento fisioterapêutico em enfermaria hospitalar, destacam-se alguns trabalhos como de: Arieiro et al. (2007) no tratamento de linfedema facial após ressecção de cabeça e pescoço; Muniz et al. (2007) no tratamento de idosos com fratura de fêmur, tendo a queda como principal causa; Lunardi et al. (2008) no tratamento complementar a esofagectomia no câncer de esôfago; Trevisan et al. (2010) no tratamento respiratório dos pacientes após cirurgia abdominal; Lima et al. (2011) no pós cirúrgico, onde encontraram o baixo acompanhamento fisioterapêutico; Dassie et al. (2011) no atendimento fisioterapêutico em queimados; Reis et al. (2012), na reabilitação fisioterapêutica de indivíduos internados em enfermaria clínica com múltiplas comorbidades; Franceshi et al. (2012) na reabilitação pulmonar em enfermaria pediátrica; Costa et al (2014) na avaliação da intervenção da

fisioterapia no equilíbrio e independência funcional em pacientes de enfermaria com média de 14 dias de internação; Conceição et al (2014) no estudo com 200 pacientes, com média de 52.6 anos, onde as doenças oncológicas eram prevalentes; Souza et al. (2014) na pesquisa com pacientes hipoxêmicos que receberam reabilitação pulmonar; e Costa et al. (2015) na aplicação de exercícios neuromusculares em pacientes internados em enfermaria, com bons resultados funcionais.

Para medir a força muscular do paciente no ambiente hospitalar, Compston (2010) cita a escala do *Medical Research Council*, simples e de baixo custo, que tem por objetivo identificar a capacidade do músculo de se contrair e vencer uma resistência imposta pelo avaliador. Ela varia de 0 a 5 pontos, sendo a máxima pontuação considerada força muscular normal e a menor, sem nenhum sinal de contração muscular.

Karuka, Silva e Navega (2011), ressaltam que uma das valências mais importantes para serem avaliadas na elaboração do plano de tratamento nos pacientes idosos hospitalizados é o equilíbrio, tanto estático como dinâmico, para o reconhecimento dos déficits e estabelecimento da identificação precoce de suscetibilidades a quedas.

No contexto de baixa mobilidade funcional, o serviço de fisioterapia é o responsável pela avaliação e conduta deste grupo de pacientes. O fisioterapeuta atua nas mais diversas desordens sejam de origem neurológica, respiratória, motora, cardíaca e hemodinâmica. O profissional colabora para minimizar os efeitos negativos que o tempo prolongado de internação hospitalar, otimizando o tratamento global, reduzindo a mortalidade e proporcionando uma melhor qualidade de vida (CONCEIÇÃO et al., 2014).

Rockwood (2005) descreve a fragilidade como uma síndrome multifacetada de perda de reservas, que aumenta o risco de vulnerabilidade a efeitos adversos, como a incapacidade funcional. Baldwin et al. (2014) complementa que ela apresenta consequências com as quedas, admissões hospitalares, fraturas e morte prematura. Clegg et al. (2013) relaciona a fragilidade ao envelhecimento e declínio dos sistemas orgânicos, como por exemplo, os pacientes frágeis internados em unidades de terapia intensiva têm desfechos mais desfavoráveis do que os não frágeis.

Segundo Ferreira et al. (2017) os pacientes frágeis acamados se mantêm em decúbito dorsal, a maior parte do tempo, resultando em alterações na mecânica diafragmática, reduzindo expansibilidade e ventilação pulmonar. Além disso, nota-se encurtamento muscular, rigidez articular e a polineuropatia do paciente crítico.

No estudo de Dirks et al. (2016) foi descrito que durante séculos o repouso no leito foi considerado uma importante ferramenta terapêutica no processo de recuperação hospitalar, como exemplo os pacientes pós cirúrgicos no infarto agudo do miocárdio. Até os anos 1970, necessitam de 4 semanas de repouso absoluto, acreditando que como a cicatrização ocorre entre 4 a 6 semanas, qualquer esforço acarretaria a ruptura do músculo cardíaco. Os autores defendem que na fase aguda é importante o repouso, porém prolongando-o ocorre perda de massa muscular, aumento de resistência à insulina e desmineralização óssea. Já o estudo de Levine e Lown (1952), concluiu que os pacientes pós-IAM, que foram estimulados a sair do leito e sentar em poltrona nos primeiros dias, não tiveram complicações.

Para Adler e Malone (2012) a reabilitação precoce é uma intervenção viável em ambiente de unidade de terapia intensiva, pois resulta em melhora da força muscular e função física na alta hospitalar, naqueles doentes gravemente acometidos.

Quanto à mobilização dos pacientes acamados, Berney et al. (2013) realizaram pesquisas na Austrália e Nova Zelândia, com abordagens realizadas em unidade de terapia intensiva e observaram que 63,5% deles não foram mobilizados. Dentre os mobilizados, o primeiro atendimento ocorreu no segundo dia após a admissão, sendo que 28% foram atividades no leito, 19% sentaram à beira do leito, 37% foram para poltrona, 25% ficaram em pé e 18% deambulam. No estudo de Nydahl et al. (2014) realizado na Alemanha, apenas 24% foram mobilizados fora do leito, sendo que 19% ficaram sentados, 2% realizaram ortostatismo ativo, 1% realizou marcha estacionária e apenas 1% deambulou. Já no estudo suíço de Sibila et al. (2017), 22% dos pacientes ficaram sentados, 2% realizaram ortostatismo, 7% realizaram marcha estacionária e 2% deambulam. Já no estudo brasileiro de Pires-Neto et al. (2015) em um hospital universitário, 90% dos pacientes receberam fisioterapia motora, dentre elas 76% estavam em ventilação mecânica, dos quais 55% realizaram atividades no leito e 29% saíram do leito.

Nydahl et al. (2017) complementam que evidências atuais demonstram que a reabilitação física precoce em pacientes graves, melhora o desempenho físico, reduz o tempo de ventilação mecânica e permanência em unidades de terapia intensiva, porém notam que as barreiras como a instabilidade fisiológica e os dispositivos interferem no nível de estímulos. Por isso, são incentivados protocolos de mobilização com foco na segurança do doente, que consigam manejar o risco da reabilitação física. Dentre os principais eventos relatados pelos autores tem-se a dessaturação de oxigênio, instabilidade hemodinâmica e remoção acidental

de cateter intravascular. Para solução desses casos, foi estabelecido retorno do paciente para o leito, manutenção de breve repouso, acréscimo de vasopressores ou fluidos e interrupção momentânea da terapia. Por fim, os autores reforçam que a mobilização precoce do doente crítico é segura e apresenta baixo risco de efeitos adversos.

Para Hodgdon et al. (2014), os eventos adversos da mobilização precoce são baixos, em menos de 4% dos pacientes, sendo na maioria das vezes transitório. Porém exige-se que os pacientes sejam cuidadosamente monitorizados e avaliados durante a intervenção.

Segundo Pires-Neto et al. (2015), a deambulação deve ser vista com um objetivo geral multiprofissional, que depende dos dispositivos invasivos acoplados no paciente, atentando a critérios de segurança e progredindo baseado nas escalas funcionais, monitorando a hemodinâmica e sinais vitais do paciente, questionando sobre o grau de esforço e mantendo uma cadeira de rodas próxima, para a necessidade de descanso ou intercorrência. Após a terapia observa-se a fixação de tubos e cateteres, assim como demais ajustes no retorno para o leito.

2.3 Aprendizado de Máquina em Saúde

2.3.1 Inteligência Artificial e Ciência de Dados

A expressão inteligência artificial sempre foi uma fonte de confusão e controvérsia, como por exemplo, se alguém utilizasse Google Maps, nos anos 1970, seria classificado como bruxo. Essa ferramenta é um exemplo de inteligência produzida, que no caso gerencia a locomoção das pessoas de forma rápida e confiável (LEWIS-KRAUS, 2016).

Para Tack (2019) a inteligência artificial pode ter repercussão positiva, através do desenvolvimento dos cuidados de saúde e suas tomadas de decisões. Ela é considerada pela capacidade computacional em resolver problemas dos seres humanos.

Sachin et al. (2019) pontuam a inteligência artificial (IA) como o desenvolvimento de operações tecnológicas que requerem o envolvimento da inteligência humana, desempenhando papel importante no avanço da tecnologia. Nesse âmbito, o aprendizado de máquina é um dos principais componentes da IA, com a capacidade de aprender com supervisão e sem supervisão. Os autores citam a aplicação dessa tecnologia para avaliação e detecção de posturas anormais.

A inteligência artificial necessita de um meio para o aprendizado, assim como nos seres humanos, e para tanto necessita de dados. A ciência de dados da saúde busca compreender as funções corporais e assim melhorar a saúde e o bem-estar das pessoas. No início da década de 2010 se previu que o conceito Big Data se espalharia por diversos setores, incluindo negócios, governo e saúde, através do desenvolvimento da computação, tecnologia da informação, tecnologia em nuvem, internet, bioestatística e bioinformática, tornando possível o armazenamento, análise e compartilhamento de grandes conjuntos de dados (OTTENBACKER, GRAHAM, FISCHER, 2019).

Em 2018, o Instituto Nacional de Saúde dos Estados Unidos definiu um plano estratégico para ciência de dados, que a definiu como um campo interdisciplinar de investigação, que a partir de abordagens quantitativas e analíticas, desenvolve processos e sistemas utilizados na extração de conhecimento e percepção de conjuntos de dados cada vez maiores e mais complexos.

Para Cott et al. (2018) os sistemas de saúde e a assistência médica encontram desafios, pois ainda não se tem a padronização dos dados e valores de referência, e também a falta de qualidade desses dados, devido a baixa adesão ou usabilidade dos sistemas. Essa baixa interoperabilidade afeta os processos operacionais e os estudos epidemiológicos.

Com relação à qualidade dos conjuntos de dados, Cott et al. (2018) expõem que muitos dos dados do serviço nacional de saúde e da assistência social dos Estados Unidos tem qualidade baixa, resultando em desperdício financeiro para limpeza dos dados. Os autores defendem que a ciência de dados, através do Big Data e da informática clínica, reconhecida pelo sistema, devem possuir missões em comum. Enquanto o primeiro é altamente regulamentado, com controle ético, metodologias estabelecidas e baseado em evidências, a informática clínica não necessita de nenhum requisito educacional específico, possui metodologias frágeis, pouco fundamento ético e evidências contestadas.

Ottenbacker, Graham e Fisher (2019), definem Big Data como conjuntos de dados com tamanhos além da capacidade das ferramentas tradicionais de capturar, limpar, gerenciar e processar informações. Ela envolve novos métodos e tecnologias e a integração de dados complexos e em grande escala. Esses dados são armazenados contendo os registros da saúde dos pacientes de avaliação e do gerenciamento nos sistemas de saúde. Os locais de armazenamento ou repositórios são os locais que guardam os dados, exemplificando o DASH apoiado pelo *National Institute for Child Health and Human Development* (NICHD) do

governo britânico. Esses repositórios disponibilizam dados anônimos para novas pesquisas e criação de novas formas de validação tecnológica. A partir disso, os autores compreendem a importância das habilidades e experiência dos profissionais da saúde ao manipular essas ferramentas.

A ciência de dados para Ottenbacher, Graham e Fisher (2019) utiliza a capacidade computacional, através dos seus processos e sistemas para analisar enormes quantidades de dados e extrair conhecimento deles. Na área da saúde e reabilitação, os termos ciência de dados e Big Data são recentes, com implicações importantes na pesquisa e prática. Elas apresentam desafios na construção das pesquisas e na cultura científica tradicional, pois os pesquisadores estão envolvidos em pesquisas clínicas prospectivas e orientados ao paciente, comumente com pequenas amostras em apenas um ambiente, já a nova tendência é produzir cientistas da reabilitação que estão familiarizados com os métodos, procedimentos de análises e interpretação em big data.

Culyer (2018) destaca que a avaliação da tecnologia em saúde se faz por um conjunto de técnicas que ajudam na tomada de decisão e impactam na saúde da população, levando em consideração as evidências econômicas e de saúde.

Quanto à necessidade de compartilhamento de dados, Ottenbacher, Graham e Fisher (2019) buscam a firmamento de uma cultura que promova a troca desses grandes volumes de dados. Eles acreditam que os dados abundantes e abertos são o futuro da pesquisa em reabilitação, insistindo na política de disponibilização, através de um repositório global, onde os dados podem ser fundidos com outros estudos projetando maiores oportunidades práticas para as pesquisas.

2.3.2 Aprendizado de Máquina

Segundo Kruse et al. (2018) o aprendizado de máquina tem a capacidade de prever um resultado, sendo executado por diferentes modelos estatísticos aos conjuntos de dados e consequente validação dos resultados, oferecendo uma maneira de melhorar o uso clínico de testes, como por exemplo nos de fragilidade corporal.

Para Tack (2019) o aprendizado de máquina é uma forma de inteligência artificial, no qual algoritmos têm por objetivo prever acontecimentos, após a aprendizagem pela interpretação dos dados. Podem ser supervisionados, onde recebem o treinamento com dados

rotulados. Ao final, interpreta um resultado a partir de entradas reais. Já o aprendizado de máquina não supervisionado identifica padrões sem o treinamento, sendo por agrupamento ou associação. Acaba sendo consenso que o refinamento e a automação das tarefas venham a reduzir custos em saúde.

Lecun, Bengio e Hinton (2015) complementam que atualmente a sociedade é impulsionada pelo aprendizado de máquina, como observado nas pesquisas na internet, filtragem nas redes sociais e recomendações no comércio eletrônico. Os sistemas criados combinam produtos de interesse do usuário, identifica objetos, transcreve e traduz textos, dentre uma infinidade de funções. As técnicas convencionais iniciais de aprendizado de máquinas não conseguiam processar os dados brutos, porém com a evolução da engenharia computacional, com o desenvolvimento de hardware e software, possibilitaram a disseminação dessa tecnologia.

Quanto à aprendizagem supervisionada, Tack (2019) comentou a utilização em imagens médicas como na interpretação de pneumonia em radiografia, após o treino com milhares de imagens rotuladas. A aplicação em dor, ainda discutível, avança com base em imagens de ressonância magnética e biomarcadores, usados para resolver problemas de classificação, isto é, sinais positivos ou negativos para a dor. Podem ser aplicados em tecnologias vestíveis, por meio da vigilância do comportamento físico, auxiliando na gestão de doenças crônicas, assim como o acompanhamento da adesão e desempenho durante a realização de um protocolo de exercícios domiciliares, identificando e modificando as atividades propostas. Outra aplicação citada foi à reabilitação do joelho, através da coleta de imagens e rotulação dos ângulos que diminuem a sobrecarga dos ligamentos e reduzem o risco de lesões.

Em aprendizado de máquina, o algoritmo *KNN* (*K-Nearests Neighbors* ou “K-vizinhos mais próximos”) é comumente utilizado em aprendizado de máquina para classificação ou regressão. A base do KNN é a suposição de que mesmas amostras terão valores semelhantes na maioria de seus testes. Para encontrar um valor para uma amostra alvo, as amostras *k* mais próximas são encontradas com base em uma métrica de distância definida, calculada usando os valores de independência, no caso dessa pesquisa, que estão presentes na amostra alvo e em uma amostra vizinha (LEE, STYCZYNSKI, 2018).

Outro algoritmo utilizado em aprendizado de máquina é o *Randon Forest* (Floresta Aleatória), que classifica um conjunto, onde cada árvore é construída a partir de uma amostra

retirada do conjunto de treinamento. Ao estabelecer o número de nós e o tamanho da árvore, a melhor divisão é encontrada, buscando a diminuição da variância do estimador, associado a um modelo de melhor desempenho, pois geralmente apenas árvores individuais possuem alta variação e maior custo (UDDIN, KHAN, HOSSAIN, MONI, 2019).

Em problemas de classificação, um algoritmo tradicionalmente utilizado é o *Support Vector Machine* (SVM – Máquina de Vetores de Suporte), derivado da teoria de aprendizagem estatística e baseado na minimização do risco estrutural. Nele, são construídos hiperplanos como superfície de decisão de modo que o intervalo entre o positivo e o negativo seja máximo, ou seja, mapeia cada item de dados em um espaço n-dimensional, classificando o dado por uma instância mais próxima do membro de determinada classe (CAO, WANG, LI, ZHANG, 2019).

Tack (2019) acredita que o aprendizado de máquina supervisionado tem grande potencial para melhorar a prática fisioterapêutica, devido à mensuração detalhada, diagnósticos mais precisos, resultando na melhora da tomada de decisão. Também cita a importância do compartilhamento de dados, para que a inovação tecnológica avance e o fisioterapeuta a utilize nas aplicações clínicas. Por fim, o aprendizado de máquina aplicado à saúde tem potencial para auxiliar em vários aspectos dos tratamentos de saúde, fornecendo intervenções mais eficazes.

2.3.2.1 Aplicações do Aprendizado de Máquina

O estudo espanhol de Sanchez-Montanes et al. (2020) foi voltado para a detecção precoce do diagnóstico de COVID-19, através do aprendizado de máquina. Os autores utilizaram 25 variáveis com 1.696 pacientes confirmados com a COVID-19 e criaram um modelo de aprendizagem supervisionada com 70% do conjunto de dados para treinamento e 30% para teste. O modelo de regressão logística atingiu uma AUC de 0,89, com sensibilidade de 81,69% e uma especificidade de 81,46%.

Iwamoto et al. (2020) estudaram a predição de dependência das atividades de vida diária em pacientes com AVC, através do aprendizado de máquina pelo algoritmo de árvore de decisão. O AVC está associado a um alto custo de saúde e social, pois as deficiências residuais geralmente são de longo prazo e os doentes acabam submetidos à terapia multidisciplinar. A predição dos cuidados após alta hospitalar é valiosa para a instituição de um programa de reabilitação. Neste estudo foi utilizada a medida de independência funcional

(MIF), como indicador de tratamento e avaliação de AVCs, sendo o desfecho final a dependência ou não dependência. Como resultado, foram registrados 994 doentes, sendo que 58,4% eram dependentes em alguma das atividades de vida diária, já o modelo de árvore de decisão aplicado alcançou 83% de precisão.

A pesquisa de Kruse et al. (2018) propôs aplicar o aprendizado de máquina para prever a mortalidade em 5 anos e imobilidade em 3 anos, em idosos belgas, após internamento hospitalar por meio da avaliação da sarcopenia e características de fragilidade. Foram usados dados de 264 homens em 29 modelos estatísticos, sendo 75% da base para treinamento e 25% para teste, sendo a área sob a curva com métrica avaliativa. Ao final, para a previsão de mortalidade em 5 anos houve uma boa precisão de 85%, enquanto para a imobilidade em 3 anos foi prevista razoavelmente com 74% de precisão. O modelo de regressão linear bayesiano apresentou melhores resultados.

Lin et al. (2020) tinham por objetivo desenvolver uma forma abreviada da escala motora de Fugl-Meyer, que é usada para avaliação de pessoas com AVC, com 50 itens de avaliação, através de uma metodologia de aprendizado de máquina, comparando as outras versões da escala, compostas com 12 e 37 itens. Os autores utilizaram uma rede neural artificial com 10 itens e realizaram a validação do modelo. Os autores utilizaram uma rede neural artificial com 10 itens e realizaram a validação do modelo. A conclusão foi de que o modelo usou menos itens, e os achados suportam a sua eficiência e tem potencial para melhorar a avaliação motora em pacientes com AVC.

Roy, Sikdar, Mahadevappa e Kumar (2018) desenvolveram uma classificação eletroencefalográfica (EEG) baseada no ato de preensão manual, com o objetivo de criar uma estrutura conceitual a partir de dados coletados e algoritmos de previsão adequados, para classificação da geração de forças apropriadas na extremidade dos dedos em 6 padrões de preensão. Os autores concluíram que a rede neural apresentou alta eficácia.


Shtar et al. (2021) usaram modelos preditivos para resultados na reabilitação de pacientes com fratura de quadril subaguda. Foram utilizados dados de 1.625 pacientes para criação de métodos baseados em aprendizado de máquina na concepção de um modelo preditivo. Para predição foram comparados algoritmos de base e modelos de aprendizagem de máquina para avaliar o ganho funcional baseado na escala FIM. Os melhores atributos de eficácia para o modelo foram o Mini-Exame do Estado Mental (MMSE), escores pré-fratura e

idade. Ainda, os autores concluíram que os modelos de aprendizado de máquina preveem resultados melhores que os modelos de regressão linear e logística.

2.3.3 Redes Neurais Artificiais

A pesquisa será desenvolvida com uma rede neural tradicional multicamadas com saída binária de acordo com a figura 1. Essas redes são semelhantes à rede perceptron, porém com mais de uma camada de neurônios ligados entre si por sinapses com pesos, associados a algoritmos de retropropagação de erro. O perceptron multicamadas consiste de três ou mais camadas, sendo uma de entrada, uma de saída e uma ou mais camadas ocultas. Essa rede é totalmente conectada, cada neurônio se conecta com certo peso, em outro neurônio da camada seguinte. Cada camada tem uma função específica, que ao final a camada de saída recebe estímulos da camada intermediária e constrói uma resposta. A rede aprende por um processo iterativo de ajustes dos pesos sinápticos, nele o ambiente estimula a rede, a rede é alterada e modificada em resposta aos estímulos. No aprendizado supervisionado, existem respostas esperadas que tivesse essa função de auxiliar e dessa diferença apresentar um sinal de erro e ajustar a rede (NORVIG, RUSSEL, 2004).

Figura 1 - Modelo Típico de Redes Neurais



Fonte: CIN-UFPE

O neurônio artificial é a unidade fundamental de processamento de uma rede neural artificial. Nelas, encontram-se três elementos básicos: a conexão de entrada, ponderada por um peso sináptico. Posteriormente tem-se um combinador linear responsável pela soma dos

valores da entrada gerando um potencial de ativação. Esse potencial de ativação é avaliado pela função de ativação, que calcula o sinal de saída do neurônio. Esses elementos definirão se a saída será zero ou um. O aprendizado geralmente ocorre por retropropagação do erro, que ocorre por processamento direto e processamento inverso. No primeiro, a entrada é aplicada a rede neural e seu efeito é propagado pela rede, camada por camada, sendo os pesos fixos. Já no processamento reverso, após o erro calculado na saída, ele acaba sendo propagado no sentido reverso, camada a camada e ao final os pesos são ajustados de acordo com a regra de correção de erro (HAYKIN, 2001).

Para Hoffmann, Brodowski, Steinhage e Grzegorzek (2021), as redes neurais são consideradas uma classe de algoritmos, aplicados em tarefas de classificação e regressão. Os autores apontam outro modelo de redes neurais, as recorrentes, nas quais os neurônios carregam ativações e fazem conexões com as camadas vistas anteriormente e úteis no aprendizado de séries temporais, em virtude da memória produzida, sendo aplicados em reconhecimento de voz e reconhecimento da escrita.

Segundo Lewis-Kraus (2016), o projeto do Google, Google Brain, foi criado com base em redes neurais artificiais, que se familiarizam com as informações, através de tentativa e erro, como fazem as crianças. Essa noção provém da década de 1940, porém muitos cientistas da computação rejeitavam tal hipótese. O projeto da Google, desde 2011, tem demonstrado que a inteligência artificial pode resolver muitos problemas, incluindo a melhora da interpretação do reconhecimento da fala e do reconhecimento de imagens. A expressão inteligência artificial é utilizada no Google Maps, que gerencia a locomoção das pessoas de forma rápida e confiável.

Na revisão de Ching et. al (2018), o Aprendizado Profundo se refere às novas uniões de técnicas, que demonstram a evolução dos algoritmos de Aprendizado de Máquina, classificando imagens e reconhecendo a voz humana, devido a sua flexibilidade e alta precisão. Além desses campos, as áreas da física, química e medicina têm se beneficiado de tais técnicas. Historicamente, a aprendizagem profunda teve início no ano de 1943, através da pesquisa sobre neurônios artificiais, a partir do funcionamento do sistema nervoso humano. Basicamente são compostos por camadas de entradas, camadas ocultas e camadas de saída, sendo que este processo é complexo, composto por eventos que ocorrem no SNC. As camadas ocultas caracterizam o aprendizado profundo, onde cada camada posterior faz o refinamento do conteúdo das anteriores.

Além da abordagem supervisionada, o aprendizado profundo pode ser usado em abordagens não supervisionadas como objetivo de resumir, explicar ou identificar padrões como uma forma de agrupamento. Numa classe binária, a rede neural simples, sem camadas ocultas, sem ciclos e com a função sigmoide na camada de saída, equivale à regressão logística, assim como na saída com resultados contínuos à regressão linear, pode ser vista como uma rede neural de camada única. Todo o avanço em inteligência artificial deve-se a melhorias de hardware e da composição de enorme conjunto de dados para treinamento das redes neurais (CHING et al., 2018).

Lecun, Bengio e Hinton (2015) afirmam que no Aprendizado Profundo as camadas ocultas não são projetadas por engenheiros ou humanos, pois são apreendidas a partir dos dados usando procedimentos de aprendizado ainda pouco conhecidos. Em 2006, um grupo do *Canadian Institute for Advanced Research* (CIFAR), retomou os estudos sobre redes profundas, introduzidos em procedimentos de aprendizagem não supervisionados, criando camadas de detectores de recursos, que eram capazes de reconstruir ou modelar as atividades das entradas brutas. No treinamento da rede, os pesos se reinicializam para valores sensíveis, sendo então uma camada de saída adicionada ao topo da rede, se ajustando através da retropropagação. Como exemplo da funcionalidade desta aplicação tem-se o reconhecimento de dígitos manuscritos e detecção de pedestres.

Os desafios para o futuro da aprendizagem de máquina envolvem essa mesma aprendizagem não supervisionada, como ocorre com os homens e animais, fazendo descobertas pela observação, e o processamento de linguagem natural, na qual a máquina poderá criar e interpretar textos, áudios e vídeos (LECUN, BENGIO, HINTON, 2015).

Como limitações das redes neurais, Lecun, Bengio e Hinton (2015) citam que em virtude da retropropagação as redes podem ser vistas como “caixas pretas”, na qual não se sabe o porquê aquela rede chegou a determinado resultado, pois não se apresenta justificativa para as respostas. O processo é considerado lento, pois algumas vezes são necessários milhares de ciclos para se reduzir os erros a níveis aceitáveis. E por fim, é difícil definir uma arquitetura ideal de rede, não existindo regras claras da quantidade de camadas intermediárias e como devem ser as conexões, sendo criados por tentativa e erro.

2.3.3.1 Aplicações das Redes Neurais

Dentre as aplicações das redes neurais voltadas aos tratamentos em saúde, Prabhu, O'Connor e Moran (2020) estudando a reabilitação cardíaca baseada em exercícios, para prevenção de recorrência de doenças cerebrovasculares, comentam que a aceitação e adesão eram muito baixas, sendo que apenas 14% a 43% dos pacientes participaram dos programas, citando o deslocamento e agenda como principais problemas. A solução seria uma plataforma para motivar o paciente a se envolver na reabilitação, utilizada em qualquer ambiente. Após ampla comparação entre as abordagens tradicionais para reconhecimento e contagem de repetições com as redes neurais convolucionais, os autores concluíram com base na arquitetura AlexNet, que as redes neurais possuíam um desempenho para o reconhecimento de exercícios, melhor que as abordagens tradicionais, com pontuação no escore F1 de 97.18%.

Ozdemir et al. (2020) estudaram o diabetes mellitus (DM), que é uma doença metabólica caracterizada por hiperglicemia crônica, resultante de alteração na produção ou ação da insulina, levando a complicações micro ou macro vasculares. Dentre as condições associadas a DM tem-se a neuropatia diabética periférica, experimentada por 50% dos diabéticos, na qual há perda da sensibilidade corporal e redução da força muscular. Também é comum a dor neuropática diabética, que afeta a qualidade de vida, assim como o aparecimento da cinesiofobia, definida com o medo excessivo de atividade física ou movimento, naqueles que sofrem de dor ou lesão crônica, culminando em perda da mobilidade, força e capacidade aeróbia. Nesse contexto, os sistemas computadorizados de apoio à decisão clínica (CDSSs) podem auxiliar os profissionais no manejo da tomada de decisão, incluindo as redes neurais e demais arquiteturas de inteligência artificial. A hipótese dos autores é utilizar as redes neurais para detectar as condições associadas ao DM, nos estágios iniciais, contribuindo para inserção dos diabéticos em programas de exercícios apropriados. Em seu estudo participaram 72 pessoas, que possuíam diagnóstico de diabetes tipo 2 há mais de 30 anos, sendo registrado a idade, gênero, duração da doença e níveis de hemoglobina glicada. A gravidade da neuropatia foi determinada pelo escore NDS, a dor foi avaliada pela escala LANSS e a cinesiofobia foi medida pela escala de tampa.

Yin et al. (2019) estudaram a fascite plantar, uma condição inflamatória que é incapacitante e causa dor no calcanhar e arco do pé, e o seu tratamento conservador pela terapia por ondas de choque, com o objetivo de identificar os fatores preditivos para um sucesso clínico mínimo, definido com uma redução de 60% no escore EVA de acordo com a

linha de base. A sessão de terapia por onda de choque foi aplicada nos grupos de baixa, moderada e alta intensidade de dor, com acompanhamento por 6 meses. No estudo foram utilizadas redes neurais artificiais com o modelo perceptron multicamadas, caracterizado pelas camadas de entrada, oculta e saída. Na camada de entrada usou-se como atributos a idade, sexo, lado afetado, duração dos sintomas, escala visual analógica, edema, presença de esporão e a pontuação de RM. Na camada de saída se atingiu ou não o sucesso clínico mínimo. Ao todo 210 pacientes participaram do estudo, sendo 10 atributos previsores. Respectivamente, a AUC demonstrou para os autores uma boa discriminação dos atributos gerando respectivamente 0.738, 0.882 e 0.520.

Przednowek et al. (2017) desenvolveram uma nova abordagem para o planejamento de treinamento de corrida de 400 metros com barreira, usando as redes neurais artificiais. Sabendo que para alcançar melhores resultados a seleção de cargas de treinamento é fundamental, para isso foram analisados 144 planos de treinamento, a partir de 21 atletas, que competiram entre 1989 e 2012. O objetivo era criar um modelo para o planejamento de cargas de treinamento. Foram utilizadas 29 variáveis e duas redes neurais, uma perceptron multicamada e outra com funções de ativação de base radial. Foi aplicada a validação cruzada e calculado o erro quadrático médio normalizado. Por fim, os autores afirmam que o modelo pode ser usado como uma ferramenta para auxiliar o treinador no planejamento de cargas para o treinamento.

Após questionamentos sobre as incertezas de recuperação em indivíduos com lesão medular, relativas às habilidades funcionais, Belliveau et al. (2016) citam ferramentas de suporte à decisão clínica, como preditores individuais e não somente ao uso da escala ASIA. Neste estudo foi comparada a precisão de dois modelos, regressão logística e redes neurais artificiais para estimar deambulação e não deambulação de longo prazo. A amostra foi composta de 3.142 indivíduos, estudados entre os anos de 2010 e 2014, com lesões medulares traumáticas, com idade superior a 18 anos e com pontuação da ASIA na admissão, tendo a média de idade de 41.5 anos. As variáveis de entrada incluíram a idade, sexo e pontuações no teste motor da ASIA. Já as variáveis de saída eram a resposta quanto à deambulação, transferência e dependência motora. Foi usada a escala FIM, que definiu de 1-5 como dependentes, 6 como dependência modificada e 7 como independentes. Ao final os modelos classificaram com precisão de 85-87% para o estado de deambulação auto relatado, após 1 ano de alta hospitalar.

García-Massó et al. (2014) realizaram um estudo em indivíduos com lesão medular, para estimar o gasto energético, a partir da frequência cardíaca. Na pesquisa foram utilizadas 20 pessoas em dez atividades físicas, monitorados e coletados o consumo máximo de oxigênio. Foram coletados dados de sete atributos como variáveis independentes. Foram utilizados dois modelos, um baseado em regressão logística linear e outro em redes neurais. Os pesquisadores encontraram uma estimativa melhor no modelo com redes neurais no uso da frequência cardíaca para estimar o consumo de oxigênio consumido em pessoas paraplégicas, durante atividade física.

O estudo de Isik e Arslan (2011) descreve e avalia uma rede neural artificial capaz de identificar microêmbolos cerebrais detectados pelo ultrassom Doppler em tempo real. Foi utilizada uma rede perceptron multicamada, para classificar o normal e anormal em pacientes com doença arterial, pois foi superior ao classificador Bayesiano. Os autores destacam a capacidade das redes neurais em reconhecer padrões e criar regras simples para resolver problemas complexos. Também apresentam capacidade de treinamento e tem boa capacidade de generalização, isto é, um dado pode ser reconhecido fora do seu conjunto original. A rede foi implementada com 4 neurônios na camada de entrada, 6 na camada oculta e 2 neurônios na camada de saída. Os tempos de ultrassom aplicados variaram de 4, 5 e 6 minutos, com valores de potência de 1.5 e 2 W/cm². O experimento atingiu-se a acurácia de 95% nos homens e 97% nas mulheres.

Na pesquisa de Rabhi, Mrabet e Fnaiech (2018) foram projetados um dispositivo de reconhecimento facial, voltado para pessoas com deficiências graves, através de um sistema de calibração comportamental integrado a interface, com a capacidade de a própria pessoa escolher as suas próprias expressões faciais, baseada em inteligência artificial. Vários algoritmos foram usados para classificação, incluindo as redes neurais *feedforward*, principalmente na biometria, especificamente no reconhecimento facial, destacando os contornos faciais, olhos, sobrancelhas, nariz e boca. Na matriz de confusão, a taxa de sucesso geral atingiu 96.91%. Na curva ROC resultante, pode-se observar que as redes neurais artificiais mostraram uma precisão máxima de 98.02%.

Kaczmarczyk, Wit, Krawczyk e Zaborski (2009) estudaram a marcha em pacientes pós-AVC, para identificar subgrupos homogêneos para um melhor direcionamento de tratamento. O objetivo dos autores foi através de redes neurais, que já são utilizadas para distinguir padrões de marcha, categorizar padrões a partir de mudanças nos ângulos

articulares durante o ciclo da marcha. Foram utilizados 74 pacientes hemiplégicos e um dos critérios de inclusão era deambular de forma independente. Em cada indivíduo, foi feita a análise de marcha pela escala (APAS), onde caminhavam por 10 metros, com 18 sensores no corpo, sendo gravado o movimento por duas câmeras. Duas etapas de avaliação, a primeira qualitativa ao alcançar o padrão normal da articulação e a segunda quantitativa, através da medida angular dos movimentos dos membros inferiores. A modelagem em redes neurais foi do tipo perceptron multicamadas, onde os valores de entrada eram valores discretos dos quadris e joelhos, e três saídas com os tipos de marcha equina (ante pé), plana (chato) e vara (calcanhar). O estudo concluiu que as redes neurais foram superiores aos outros métodos, atingindo 100% de acerto, considerando a angulação do joelho, para os três padrões de marcha. Para o quadril no plano sagital, o menor acerto foi de 97% para a marcha com o pé chato e no plano frontal, 95% de acerto para o padrão pé chato e varo e 85% para o padrão equino.

Segundo Johnsson et al. (2020), o objetivo da pesquisa foi investigar uma rede neural artificial para detectar as dependências entre as variáveis clínicas disponíveis na admissão hospitalar e realizar previsões precoces do resultado funcional. A amostra conteve 939 pacientes, sendo que os dados foram categorizados totalizando 54 variáveis. A escala de saída foi à categoria de desempenho cerebral, avaliada em 180 dias, sendo que a pontuação variou de 1-2 mostrando bom desempenho, com pacientes independentes para as atividades diárias, que podem ter uma deficiência menor, e entre 3-5, com um mau resultado funcional, incluindo pacientes em estado vegetativo e mortos. No modelo de redes neurais, 10% foram usados para teste e 90% para treinamento e realizada validação cruzada. Como resultados, 47% apresentaram um bom resultado e 53% um mau resultado funcional. A rede neural apresentou uma boa capacidade de predizer o resultado em 6 meses, com AUC de 0.852 na validação cruzada e 0.891 no conjunto de validação interna independente.

E por fim, Falavigna et al. (2019) realizaram um estudo sobre a tomada de decisão, em hospitalizar o paciente após um evento de síncope. Nesses casos são usadas as regras dos escores SFSR (*Saint Francis Syncope Rule*) e OESIL (*Osservatorio Epidemiológico sulla Sincope nel Lazio*) que estratificam o risco de desfechos graves. Esse trabalho propôs um algoritmo baseado em redes neurais artificiais para estratificação desses desfechos. Foram utilizados 1.825 registros, sendo considerados os desfechos morte, necessidade de procedimento terapêutico importante e readmissão precoce. As redes neurais foram escolhidas devido ao alto poder de generalização e apresentaram bom desempenho.

3 MÉTODOS

3.1 TIPO DE ESTUDO

Esse estudo foi considerado um estudo metodológico e de desenvolvimento tecnológico. Segundo Polit e Beck (2011), os estudos metodológicos envolvem desenvolver, validar e avaliar ferramentas e métodos de pesquisa. Por ter como objetivos desenvolver e propor um modelo preditivo baseado em algoritmos de Aprendizado de Máquina é considerado de desenvolvimento tecnológico, que por sua definição está focado no desenvolvimento de novos instrumentos.

Na pesquisa tecnológica, os objetivos devem ser claros e precisos, sendo destacada a relação entre custos e benefícios dos resultados alcançados. Cupani (2011) destaca que inovações tecnológicas podem resultar em revoluções científicas. Nesse contexto, a pesquisa tecnológica deve basear-se em enunciados e métodos científicos, para manter a evolução segura e consciente da inovação.

3.2 NATUREZA DO ESTUDO

Quanto à natureza do estudo a pesquisa foi quantitativa. De acordo com Mendes e De Sordi (2013) uma pesquisa quantitativa se caracteriza por: 1) propósito: busca explicações e previsões para desenvolvimento das generalizações; 2) processo: as variáveis são conhecidas, diretrizes e métodos estabelecidos e pré-determinados, objetivos; 3) coleta de dados, numérica, com grande amostra e padronização; 4) análise dos dados estatística, objetiva e raciocínio dedutivo; 5) achados, números, estatísticas, dados agregados e estilo científico tradicional.

No contexto do estudo, caracteriza-se pela coleta e tratamento dos atributos do conjunto de dados, utilizados para treinamento e teste do modelo de Aprendizado de Máquina.

3.3 LOCAL DO ESTUDO

A pesquisa foi desenvolvida com a base de dados oriunda do Hospital Universitário Polydoro Ernani de São Thiago da Universidade Federal de Santa Catarina – HU/UFSC. Salientando que os autores receberam a carta de anuência da instituição e o parecer consubstanciado do Comitê de Ética em Pesquisas com Seres Humanos (CEPSH-UFSC).

3.4 BASE DE DADOS

O Setor de Gerência de Ensino e Pesquisa do Hospital Universitário da UFSC (GEP) aprovou a através da carta de anuência nº 10/2021/SGPIT/GEP/HU-UFSC-EBSERH, e após declaração de anonimização do conjunto de dados, pela chefia do Setor de Reabilitação, o uso dos dados dos pacientes atendidos pelo serviço de fisioterapia, nas enfermarias do hospital universitário, entre os meses de janeiro e dezembro de 2020.

O pré-processamento de dados foi iniciado com o recebimento dos arquivos no formato XLSX, sendo utilizado o programa Excel para leitura. Os arquivos estavam divididos por unidade de enfermaria contendo duas planilhas com os dados de admissão e alta. Já com a posse dos valores dos dados, houve a necessidade de adequá-los, condensando os atributos e registros em apenas uma planilha, por unidade.

A união das planilhas resultou em:

- Unidade de Clínica Médica I - 332 registros;
- Unidade de Clínica Médica II - 312 registros;
- Unidade de Clínica Médica IV - 64 registros;
- Unidade de Clínica Cirúrgica I - 495 registros;
- Unidade de Clínica Cirúrgica II - 441 registros.

Ao todo, 23 atributos com 1.644 registros foram contabilizados nas cinco planilhas. Para uso futuro na análise preditiva do modelo de Aprendizado de Máquina optou-se por unificá-las em apenas uma planilha.

Com base nesses dados brutos foi realizada apenas uma análise sobre o tempo total de internação hospitalar, alcançando uma média de 14,59 dias. Porém esse atributo apresentou centenas de dados faltantes, o que poderia influenciar no aprendizado do modelo, por isso o atributo “tempo de internação hospitalar” foi excluído do conjunto de dados. Esse atributo apresentou muitos campos não preenchidos, principalmente em virtude de o profissional não conseguir acompanhar a localização do paciente durante todo o internamento e suas transferências internas. Além disso, os registros que não tinham a variável “saída” preenchido foram excluídos. Comumente os campos que estão em branco são substituídos pela média ou mediana ou ainda excluído do conjunto de dados, mas como na base de dados, a exclusão de registros faria perder muitas informações ou não condizer com os demais atributos de cada registro, foi optado pelo preenchimento manual, caracterizado pela compatibilidade com os demais atributos. Nesse momento, a planilha contava com 22 colunas e 1.573 registros.

Para evitar o viés da pesquisa, foi adotado para o modelo apenas as classes, ou seja, dependentes e independentes, excluindo registros dos óbitos e dos menores de 18 anos. Ao final, foram 22 atributos com 1386 registros.

A planilha em formato XLSX foi convertida para o modo CSV (*comma-separated-values*), isto é, valores separados por vírgulas, para facilitar a manipulação pelas bibliotecas do Python. Após a conversão foi feito o upload do arquivo CSV na plataforma do Google Colab, isto é, um serviço em nuvem, utilizado para criação e execução de códigos da programação em Python.

3.5 POPULAÇÃO E AMOSTRA

Na população foram incluídos todos os pacientes internados em unidade de clínica médica e cirúrgica que foram avaliados e atendidos pelo serviço de fisioterapia, dos meses de janeiro a dezembro de 2020, independente de sexo, doença, história médica atual e o estado de saúde prévio, porém foram excluídos os casos de óbitos e os registros dos menores de idade. Ao final da preparação conjunto de dados foram definidos que 22 atributos com 1.386 registros de seriam utilizados no estudo.

Quanto ao risco de exposição dos dados dos participantes, pode-se garantir sua segurança, pois os registros são anônimos. Salientando que os pesquisadores desconhecem os participantes da pesquisa, que será suspensa caso o conjunto de dados históricos do serviço de fisioterapia seja suprimido.

3.6 ATRIBUTOS DE SELEÇÃO E IDENTIFICAÇÃO

Os dados obtidos na planilha foram adequados ao estudo, sendo uma limitação e que os campos faltantes foram preenchidos de acordo com a expertise do pesquisador, pois a inserção desses elementos foi importante para o treinamento do modelo e poderiam refletir na acurácia final. Os dados categóricos foram classificados por numerais e abaixo se tem a discriminação de todos os valores atribuídos as variáveis, sendo eles:

- **Sexo:** ao atributo sexo foi definido os valores de:

0 = Feminino;

1 = Masculino.

- **Idade:** é um numeral. No estudo e de acordo com a idade mínima permitida para o internamento em enfermaria adulto, isto é, 14 anos. Para o desenvolvimento do modelo foi adotado o mínimo de 18 anos.

- **Diagnóstico principal:** de acordo com o preenchimento dos fisioterapeutas, foi observado centenas de diagnósticos, com grande variação de terminologia das doenças e baixa padronização, e como forma de facilitar o processamento e aplicação do modelo de aprendizado de máquina, houve a necessidade de categorizar os diagnósticos em 23 condições de saúde, como por exemplo, diagnósticos da exacerbação da doença pulmonar obstrutiva crônica e pneumonia foram classificados como doença pulmonar, AVC e mielite transversa como doença neurológica, leucemia mieloide aguda e linfoma de Burkitt com doença onco-hematológica, hepatite e cirrose como doença hepática, laparotomia exploratória como cirurgia torácica abdominal e pélvica, entre outros. Por fim, os diagnósticos principais foram classificados da seguinte forma:

- 1 = Doença pulmonar;
- 2 = Doença neurológica;
- 3 = Doença onco-hematológica;
- 4 = Doença cardíaca;
- 5 = Doença hepática;
- 6 = Cirurgia torácica, abdominal e pélvica;
- 7 = Doença cardiovascular;
- 8 = Câncer do aparelho gastrointestinal, urinário e mama;
- 9 = Sepsis;
- 10 = Doença gastrointestinal;
- 11 = Doença renal e trato urinário;
- 12 = Câncer de pulmão;
- 13 = Intoxicação exógena;
- 14 = Câncer metastático;
- 15 = Celulite e abscesso;
- 16 = Osteomielite;
- 17 = Amputação de membro inferior;
- 18 = Doença arterial obstrutiva periférica ou venosa;
- 19 = Doença psiquiátrica;
- 20 = Doença reumática;

21 = Diabetes mellitus descompensado;

22 = Grande queimado;

23 = Cirurgia de cabeça e pescoço.

- **Procedência:** esse atributo caracteriza de onde o paciente foi encaminhado, isto é, do setor do qual foi transferido, sendo destacado:

0 = Emergência;

1 = Unidade de Terapia Intensiva;

2 = Unidade de Clínica Médica;

3 = Unidade de Clínica Cirúrgica/Centro Cirúrgico;

4 = Transferência Hospitalar;

5 = Unidade Ginecológica, Obstétrica e Alojamento Conjunto;

6 = Ambulatório;

7 = Internamento Eletivo.

- **Nível de Consciência na Admissão e Saída:** para avaliação do nível de consciência foi utilizada a Escala de Coma de Glasgow, como disposta na tabela 1. A escala possui três critérios de classificação, sendo a abertura ocular, resposta verbal e resposta motora, que são pontuados e cuja soma dos valores selecionados em cada um dos três grupos varia de três a quinze pontos. A pontuação três classifica o paciente como sem nenhuma resposta ao estímulo e quinze considera-se um nível normal de resposta.

Tabela 1 - Escala de Coma de Glasgow

Escala de Coma de Glasgow		
Parâmetro	Resposta obtida	Pontuação
Abertura ocular	Espontânea	4
	Ao estímulo sonoro	3
	Ao estímulo de pressão	2
	Nenhuma	1
Resposta verbal	Orientada	5
	Confusa	4
	Verbaliza palavras soltas	3
	Verbaliza sons	2
Resposta motora	Nenhuma	1
	Obedece comandos	6
	Localiza estímulo	5
	Flexão normal	4
	Flexão anormal	3
	Extensão anormal	2
	Nenhuma	1

Fonte: TEASDALE e JENNETT, 1974.

- **Dias de internação na unidade:** contabiliza todos os dias que o paciente permaneceu internado na unidade de enfermaria.
- **Número de atendimentos:** permite obter o número de atendimentos realizados pelo Fisioterapeuta durante a estadia do paciente na enfermaria.
- **Escala EMU (Escala de Mobilidade em Unidade de Terapia Intensiva):** permite classificar o nível de mobilidade funcional do paciente, sendo adotado pelos profissionais da Fisioterapia do HU/UFSC, incluindo a unidade de terapia intensiva e as unidades de enfermaria. Seus valores vão de zero, isto é, nenhuma mobilidade, até a pontuação 10, que significa máxima independência para deambulação, como mostra a tabela 2. Essa escala foi aplicada na admissão e saída, porém também demonstra a máxima mobilidade observada durante a internação.

Tabela 2 - Escala EMU

CÓD	ESCALA EMU
0	Nada, deitado no leito;
1	Sentado no leito, exercícios no leito;
2	Transferido passivamente para a cadeira (sem ortostatismo);
3	Sentado à beira do leito;
4	Ortostatismo;
5	Transferência do leito para cadeira;
6	Marcha estacionária (à beira do leito);
7	Deambulando com auxílio de duas ou mais pessoas;
8	Deambulando com auxílio de uma pessoa;
9	Deambulando independentemente com auxílio de um dispositivo de marcha;
10	Deambulação independentemente sem auxílio de um dispositivo de marcha.

Fonte: Serviço de Fisioterapia HU/UFSC

- **Protocolo de Mobilização Precoce:** de acordo com a figura 2, pode-se acompanhar a evolução ou regressão do quadro durante a intervenção do fisioterapeuta. O protocolo varia de 1 a 5, avaliado na admissão e saída.

Figura 2 - Protocolo de Mobilização Precoce



Fonte: Serviço de Fisioterapia HU/UFSC

- **Escala MRC (Medical Research Council):** mede a força muscular, com graduação que varia de zero, isto é, nenhuma contração muscular detectável até 60 pontos, com força muscular normal em membros superiores e inferiores, como mostrado na figura 2. Salientando que o teste é realizado bilateralmente, testando os movimentos de abdução do ombro, flexão de cotovelo, extensão do punho, flexão do quadril, extensão do joelho e dorsiflexão do tornozelo. Quanto ao grau de força têm-se os valores: 0 para nenhuma contração visível, 1 para contração visível sem movimento do segmento, 2 para movimento ativo com eliminação da gravidade, 3 para movimento ativo contra a gravidade, 4 para o movimento ativo contra a gravidade e resistência e 5 para força normal.

- **Suporte Ventilatório:** descreve de que forma o paciente foi admitido e saiu da enfermaria, com relação à necessidade de melhora do aporte de oxigênio ou ventilação, estimado como:

0 = Ar ambiente;

1 = Cânula nasal de oxigênio;

2 = Macro nebulização;

3 = Máscara com reservatório de oxigênio ou Máscara de Venturi;

4 = Ventilação Não-Invasiva;

5 = Ventilação Mecânica Invasiva.

- **Via Aérea Artificial:** descreve que o paciente fez uso ou não houve necessidade de intubação ou cânula de traqueostomia, definida como:

0 = Não;

1 = Sim.

- **Ventilação Não Invasiva:** descreve o uso ou não da necessidade de ventilação não invasiva, definido por:

0 = Não;

1 = Sim.

- **Tempo de Ventilação Não Invasiva:** descrita em dias, contabiliza o tempo de adaptação da interface da ventilação não invasiva.

- **Ventilação Mecânica Invasiva:** atribuiu a necessidade de ventilação invasiva, após intubação na enfermaria, classificada como:

0 = Não;

1 = Sim.

- **Tempo de Ventilação Mecânica Invasiva:** contabiliza o tempo em horas da utilização dessa forma de ventilação da unidade.

- **Saída:** define o destino do paciente internado na enfermaria, sendo inferido como:

0 = Óbito;

1 = Alta;

2 = Transferência interna;

3 = Transferência externa;

4 = Transferência UTI;

5 = Alta Fisioterapêutica;

6 = Evasão.

3.7 CONSIDERAÇÕES ÉTICAS

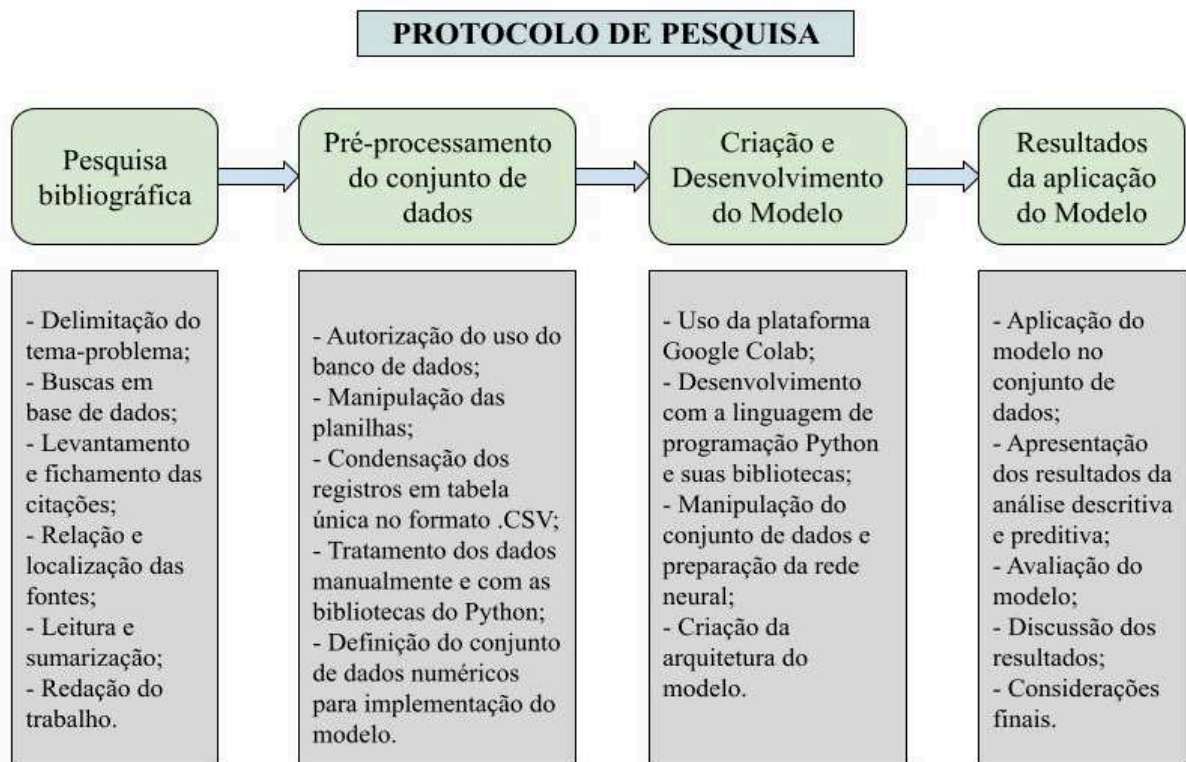
O estudo respeitou a resolução 466/2012 do Conselho Nacional de Saúde que estabelece as Diretrizes e Normas Regulamentadoras de Pesquisa Envolvendo Seres Humanos. Os pesquisadores assinaram o termo de confidencialidade para com os dados do estudo. A chefia do Serviço de Fisioterapia autorizou o uso do conjunto de dados pela

anonimização dos registros, assim o termo de consentimento livre e esclarecido foi dispensado. O Setor de Gerência de Ensino e Pesquisa do Hospital Universitário da UFSC (GEP) aprovou a através da carta de anuência nº 10/2021/SGPIT/GEP/HU-UFSC-EBSERH, o uso dos dados para fins de pesquisa. E por fim, o parecer consubstanciado do Comitê de Ética em Pesquisas com Seres Humanos (CEPSH-UFSC), sob o CAAE: 48287821.8.0000.0121, permitiu o prosseguimento da pesquisa, pois obedeceu aos princípios éticos. Os documentos estão anexados nos apêndices.

3.8 PROTOCOLO DO ESTUDO

A pesquisa engloba quatro etapas, como dispostas no quadro 1, detalhadas a seguir:

Quadro 1 - Protocolo de Pesquisa



Fonte: Autor

3.8.1 Etapa 1 - Pesquisa Bibliográfica

Inicialmente, foi coletado o substrato da pesquisa, com aprofundamento do conhecimento de conceitos de mobilidade funcional, análise preditiva, fisioterapia e reabilitação, inteligência artificial e Aprendizado de Máquina. O estudo envolveu o

levantamento bibliográfico, utilizando prioritariamente a base de dados PUBMED com os termos, “*predictive analysis*”, “*bedridden in the hospital*” e “*physiotherapy and rehabilitation*” que atendessem a formulação do modelo de redes neurais artificiais e sua aplicação ao conjunto de dados.

3.8.2 Etapa 2 - Pré-processamento do Conjunto de Dados

O conjunto de dados foi disponibilizado pelo serviço de Fisioterapia do Hospital Universitário da UFSC. De modo a proteger a privacidade, foram removidos os dados como número do registro hospitalar e nome do paciente. Com o conhecimento dos atributos da tabela, realizou-se o tratamento dos dados a serem utilizados, como relatados no tópico 3.4 em base de dados.

Nessa etapa, além da manipulação manual, foram utilizadas bibliotecas de linguagem de programação Python para manipulação dos atributos e seus valores, através de métodos, parâmetros e funções das bibliotecas Pandas, Numpy e Matplotlib. Nesse momento foi criado o arquivo “Previsores.csv” com os atributos “Sexo”, “Idade”, “Diagnóstico Principal”, “Procedência”, “Nível de Consciência Admissão”, “Nível de Consciência na Saída”, “Dias de Internação na Unidade”, “Número de Atendimentos”, “EMU na Admissão”, “EMU máximo alcançado na Internação”, “Fase do Protocolo na Admissão”, “Fase do Protocolo na Saída”, “Força Muscular na Alta (MRC)”, “Suporte Ventilatório na Admissão”, “Suporte Ventilatório na Alta”, “Via Aérea Artificial”, “Uso de VNI”, “Tempo de Uso da VNI (Dias)”, “Uso de VMI”, “Tempo de VM (horas)” e “Saída”. O segundo arquivo criado foi definido como “Classe.csv”, utilizando o atributo “EMU na Alta”.

Um dos pontos mais relevantes desta etapa foi à definição da camada de saída da rede neural artificial, sendo classificada a escala de mobilidade funcional (EMU) como o desfecho final a ser analisado na predição. Por isso, foi graduado o valor entre 1 a 8 como dependência e os valores 9 e 10 como independência para as atividades que envolvem mobilidade como sair do leito, ir ao banheiro e deambular.

Nesse contexto, foi criada a função chamada `classifica_mobilidade`, na plataforma Google Colab, na qual valores entre 1 e 8, retorna “0”, isto é, dependência, enquanto 9 e 10, retornam “1”, ou seja, independência.

3.8.3 Etapa 3 - Criação e Desenvolvimento do Modelo


Com os dados numéricos ajustados em tabela, pode-se a partir do Google Colab e pela linguagem Python e bibliotecas Scikit-learn e Keras, criar e aplicar o modelo de rede neural artificial binária multicamadas.

O método `train_test_split` da biblioteca `Sklearn.model_selection` foi importado para realizar a separação do conjunto de dados em treinamento e teste, sendo definido que 80% do conjunto de dados foi para treinamento para treinamento e 20% para teste, pois foi citada em diversos estudos, seguindo o princípio de Pareto. Mesmo alterando essas margens na execução do modelo, não houve diferença significativa na acurácia do treinamento.

Nesse momento foi criada a estrutura da rede neural para ajustes dos pesos. O classificador recebeu a função `Sequential` para inicializar o modelo, sendo formada a camada de entrada, adicionado o método `Dense`, na criação de três camadas ocultas, sendo 21 atributos de entrada, 11 neurônios nas camadas ocultas e 1 neurônio na camada de saída, conforme a figura 3. Nas camadas ocultas foi usada a função de ativação “*Relu*”, que retorna valores zero e positivos. Já na camada de saída foi utilizada a função de ativação “*Sigmoid*”, usado em problemas de duas classes, que gera uma probabilidade positiva. Para a compilação do classificador foi utilizado o otimizador “*Adam*”, como função de perda chamada `binary_crossentropy` e a métrica usada foi a `binary_accuracy`, obtidas da documentação do Keras.

No segundo momento, para validação cruzada do modelo, foi criada uma função ao classificador inicial, utilizando os métodos do `kerasClassifier` atribuindo a função criada, o tamanho do lote de 10, com 200 épocas a serem estimadas. Assim, pôde-se usar o método `cross_val_score`, para estimar, os previsores e a classe, com $k = 10$, isto é, 10 grupos, sendo a acurácia como escala de avaliação.

Figura 3 - Modelo da Rede Neural Artificial
Modelo de Rede Neural Artificial para Resposta Binária



Fonte: Autor

3.8.4 Etapa 4 - Resultados do Modelo

Nessa etapa foram expostos os resultados na análise exploratória, que avaliou a contribuição do serviço de Fisioterapia no tratamento da mobilidade física dos pacientes atendidos em enfermaria e também os resultados de acurácia, precisão, sensibilidade, especificidade, escore F1 e a Curva ROC-AUC, para mensurar a qualidade do modelo de redes neurais desenvolvido.

3.9 MÉTRICAS DE VALIDAÇÃO DO MODELO

Há diferentes formas para avaliação de modelos preditivos, cujo principal objetivo é verificar se o modelo definido é efetivamente eficiente, dessa forma trazendo maior confiança em sua aplicabilidade. A primeira medida de avaliação é a validação cruzada, que mede a capacidade de generalização do modelo e a segunda é a matriz de confusão, que avalia o desempenho do modelo (VASCONCELOS, NETO, TELLES, 2018).

Foram utilizados no estudo os parâmetros a seguir:

- Positivo Verdadeiro (True Positive – TP);
- Falso Positivo (False Positive – FP);
- Negativo Verdadeiro (True Negative – TN);
- Falso Negativo (False Negative – FN).

A partir desses parâmetros, observam-se as taxas de erros e acertos, que incluem:

- Acurácia, que mede a exatidão e a precisão dos dados analisados. É calculada por $ACC = TP + TN / TP + FP + TN + FN$;

- Taxa Positiva Verdadeira (True Positive Rate – TPR) ou sensibilidade/recall é a proporção de resultados corretamente classificados como positivos no resultado do modelo. Este resultado é comparado com todos os valores definidos como positivos na amostra, sendo calculada como $TPR = TP / TP + FN$;

- Taxa Negativa Verdadeira (True Negative Rate – TNR) ou especificidade é a proporção de resultados classificados como negativos, fora de todas as instâncias que não eram originalmente negativos. É calculada com $TNR = TN / TN + FP$;

- Taxa de Precisão, que mede o grau da variação de resultados de uma mediação. É calculada por $PRECISÃO = TP / TP + FP$;

- Escore F1, que mede o grau de desempenho do modelo. É calculada por $F1 = 2 * (precisão * sensibilidade / (precisão + sensibilidade))$.

No estudo também será usada a métrica AUC (Area Under the Curve), ou seja, a área sob a curva ROC (Receiver Operating Characteristic), que é a probabilidade de um classificador ficar mais confiante no exemplo positivo, escolhido aleatoriamente realmente positivo, do que um exemplo negativo selecionado aleatoriamente positivo. A AUC fornece uma medida agregada de desempenho em todos os possíveis limites de classificação.

No estudo também como parte da avaliação do modelo é feita a validação cruzada, caracterizada pela partição do conjunto de dados em subconjuntos mutuamente exclusivos, empregados para a legitimidade do sistema, cujo objetivo é estimar a capacidade de generalização do modelo (HAYKIN, 2001).

Um modelo preditivo que tenha bom desempenho resultará em uma alta sensibilidade e especificidade, com baixa taxa de falsos positivos e falsos negativos.

4 RESULTADOS

4.1 Perfil dos Pacientes

A análise descritiva descreve as principais tendências do agrupamento de dados. Para a análise do estudo, foi utilizada a amostra inicial com 22 atributos e 1573 registros. Dos internados nas unidades de enfermaria, 50,97% eram do sexo feminino e 49,03% do sexo masculino. Com relação à idade dos pacientes atendidos pelo serviço, variou-se entre 14 e 97 anos, com uma média de 59,56 (dp: 16,92) anos, sendo a mediana de 61 e a moda de 66 anos.

Foi encontrado no conjunto de dados centenas de diagnósticos, por isso as condições clínicas foram divididas em 23 categorias. Para constatação, os grupos que mais receberam atendimento Fisioterapêutico foram àqueles acometidos por patologias pulmonares em 30,96% e nos procedimentos cirúrgicos torácicos, abdominais e pélvicos em 24,57% dos casos.

No estudo, foi observado nas unidades de enfermaria clínica e cirúrgica que os três principais setores que transferiram pacientes para essas unidades, incluíam a unidade de emergência com 55,26% das admissões, 21,53% deles providos da UTI e outros 15,43% do centro cirúrgico.

Um dos parâmetros utilizados na avaliação fisioterapêutica foi o nível de consciência da admissão e na saída da unidade, isto é, verificar o grau de alerta do indivíduo. Na admissão, 84,20% dos avaliados apresentaram pontuação 15 na Escala de Coma de Glasgow (ECG), sendo considerada normal. Na saída, constatou-se que 84,79% dos pacientes apresentavam ECG 15. Concluiu-se que o estado de alerta foi pouco alterado.

Com relação ao tempo de permanência internado para unidade de enfermaria, contabilizou-se em média de 8,82 (dp: 12,83) dias, com mediana de 6 dias.

A escala de mobilização em unidade de terapia Intensiva (EMU) foi adotada pelo serviço de Fisioterapia para avaliar o grau de capacidade de transferência, mobilidade e deambulação. Essa escala varia de 0 a 10 pontos, sendo 0 acamado, sem capacidade de movimentação, e 10 deambulação independente. Na admissão, a média da EMU foi de 6,32 pontos e mediana de 8 pontos, com 34,69% apresentando 10 pontos. Na saída foi observada uma média de 7,37 pontos com a mediana de 10, onde 51,89% alcançaram 10 pontos, isto é, totalmente independentes para deambulação.

A atuação Fisioterapêutica no Hospital Universitário adota o protocolo de mobilização precoce com 5 etapas de exercícios, envolvendo quatro gatilhos para mudança de

fases, isto é, a mobilização passiva/assistida, ortostatismo, deambulação assistida e deambulação livre. Durante a análise dos dados foi encontrado que na admissão 15,97% se encontravam na fase 1, 16,95% na fase 2, 18,80% na fase 3, 27,58% na fase 4 e 20,70% na fase 5. Após a intervenção e acompanhamento Fisioterapêutico, na saída foi constatado que 13,17% estavam na fase 1, 9,43% na fase 2, 9,90% na fase 3, 30,95% na fase 4 e 36,56% na fase 5.

Outra escala utilizada para avaliação musculoesquelética, é a MRC (*Medical Research Council*), que mede a força muscular, variando de 0, isto é, sem contração muscular, até 60 pontos, com força preservada. A MRC foi aplicada na saída da unidade, apresentando uma média de 47,96 pontos e mediana de 60 pontos.

Uma das maiores preocupações do fisioterapeuta hospitalar é a condição respiratória do paciente. Nesse banco de dados são encontrados valores de alguns atributos relativos à avaliação e acompanhamento respiratório. Quanto ao suporte ventilatório, durante a avaliação 67,55% estavam em ar ambiente, 26,85% faziam uso de cânula nasal de oxigênio, enquanto outros 5,6% faziam uso de outro dispositivo, como a máscara de Venturi. Na saída, 89,73% estavam respirando em ar ambiente, isto é, com quadro estável e valores normais de saturação de oxigênio. Apenas 2,18% fizeram uso de via aérea artificial durante a internação, isto é, intubação ou cânula de traqueostomia. Salientando que em virtude da pandemia, apenas 3,28% dos pacientes fizeram uso de ventilação não invasiva, por inicialmente ser contraindicado pela produção e dissipação aerossóis do Sars-Cov2. E por fim, notou-se que a partir de intercorrências, 0,55% dos avaliados foram submetidos à ventilação mecânica invasiva nas enfermarias.

O atendimento fisioterapêutico busca a estimulação da função motora e respiratória. Na amostra foram dispensados 7.433 atendimentos, durante o ano de 2020, aos internados em enfermaria, com uma média 4,85 (dp: 5,89) atendimentos e mediana de 3 atendimentos por paciente.

Por fim, a meta da reabilitação é a alta hospitalar. Com relação à saída, 69,73% foram de alta para o domicílio, 3,19% receberam alta fisioterapêutica, pois atingiram boa capacidade motora sem queixas respiratórias, 7,79% foram transferidos para UTI, enquanto as transferências internas e externas totalizaram 10,22%, com apenas um caso de evasão e 9,06% de óbitos.

4.2 Aplicação do Modelo

Um modelo de Aprendizado de Máquina foi criado para resolver nosso problema de pesquisa e estimar resultados. Toda a construção do modelo, baseada em redes neurais artificiais. Para treinamento e teste foi utilizado o conjunto de dados do Serviço de Fisioterapia do Hospital Universitário da UFSC, com 22 atributos de avaliação hospitalar da capacidade física, mobilidade e função respiratória.

O projeto foi construído na plataforma Google Colab, através da linguagem Python, e bibliotecas Panda, Numpy, Sklearn, Matplotlib e Keras. O conjunto de dados contou com 22 atributos e 1.386 registros. Posteriormente foi criado o arquivo chamado “Previsores.csv” com os atributos “Sexo”, “Idade”, “Diagnóstico Principal”, “Procedência”, “Nível de Consciência Admissão”, “Nível de Consciência na Saída”, “Dias de Internação na Unidade”, “Número de Atendimentos”, “EMU na Admissão”, “EMU Máximo alcançado na Internação”, “Fase do Protocolo na Admissão”, “Fase do Protocolo na Saída”, “Força Muscular na Alta (MRC)”, “Suporte Ventilatório na Admissão”, “Suporte Ventilatório na Alta”, “Via Aérea Artificial”, “Uso de VNI”, “Tempo de Uso da VNI (Dias)”, “Uso de VMI”, “Tempo de VM (horas)” e “Saída”. Para desfecho foi criado o arquivo “Classe.csv”, utilizando o atributo “EMU na Alta”.

A função para classificação da mobilidade foi elaborada para as classes dependentes e independentes. O método estabelecido foi de 80% da base para treinamento e 20% para teste. Assim a estrutura da rede neural tradicional multicamadas de resposta binária pode ser desenvolvida, cujo objetivo é o ajuste dos pesos dos atributos, após seu treinamento. A arquitetura envolveu a criação de três camadas ocultas, sendo 21 atributos de entrada, 11 neurônios nas camadas ocultas e um neurônio na camada de saída. O classificador foi compilado e foi avaliado pela acurácia e perda.

O classificador transformou e normalizou os dados dos previsores e classe de treinamento, sendo definido o tamanho de lote de 10, com 200 épocas. A partir desse momento foram utilizadas duas métricas para avaliação do classificador, isto é a validação cruzada que avalia a capacidade de generalização do modelo e a matriz de confusão, que avalia o desempenho do modelo.

A **primeira métrica** foi à validação cruzada, caracterizada pela partição do conjunto de dados em subconjuntos mutuamente exclusivos, empregados para a legitimidade do sistema, cujo objetivo é estimar a capacidade de generalização do modelo. Para tal, foi

importado o método `cross_val_score`. O classificador foi desenvolvido com o tamanho do lote de 10, com 200 épocas. Assim, com $k = 10$, isto é, 10 grupos, sendo a acurácia como escala de avaliação. Esse método exige mais do processamento computacional e é mais longo o processo de contemplação dos resultados. Após o modelo ser executado, chegou-se a um resultado de acurácia de 93.21% e desvio padrão de 0,030, de acordo com a figura 4.

Figura 4 - Validação Cruzada

```
#Validação Cruzada
media = resultados.mean()
media
```

```
0.932118652903764
```

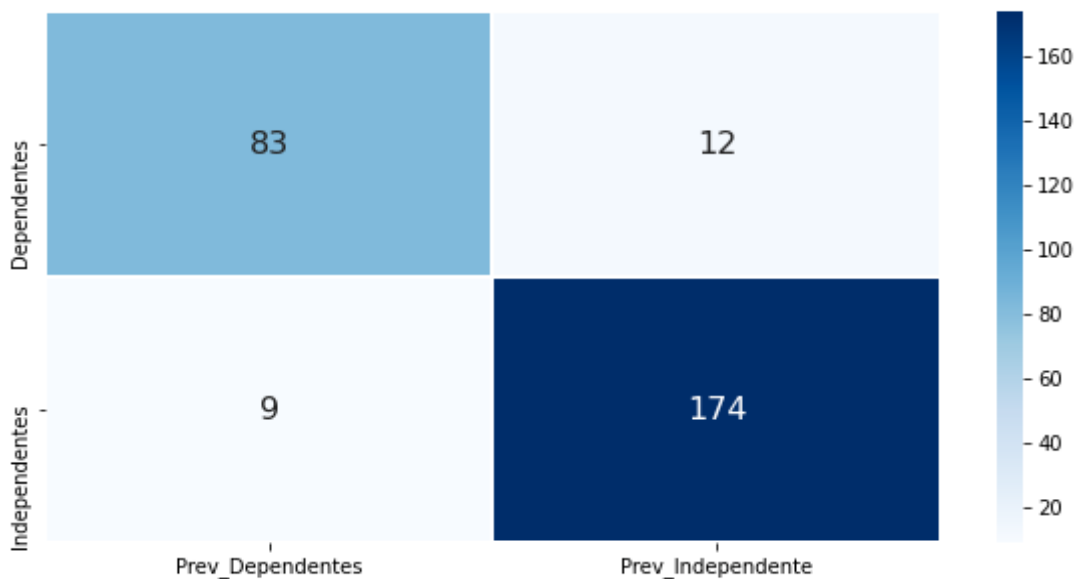
```
desvio = resultados.std()
desvio
```

```
0.03033728485932471
```

Fonte: Autor

A **segunda métrica** é a matriz de confusão (disposta na figura 5), que avalia o desempenho do modelo.

Figura 5 - Matriz de Confusão



Fonte: Autor

O relatório de classificação é destacado na figura 6.

Figura 6 - Relatório de Classificação

	precision	recall	f1-score	support
0	0.90	0.87	0.89	95
1	0.94	0.95	0.94	183
accuracy			0.92	278
macro avg	0.92	0.91	0.92	278
weighted avg	0.92	0.92	0.92	278

Fonte: Autor

Na figura 7 tem-se o resultado das métricas acurácia, precisão, sensibilidade, especificidade e o F1_Score.

Figura 7 - Acurácia, Precisão, Sensibilidade, Especificidade e F1_Score

```
#Acurácia
acuracia = print((TP+TN) / (TP+TN+FP+FN))
acuracia

0.9244604316546763

#Precisão
precisao = print(TP / (TP+FP))
precisao

0.9354838709677419

#sensibilidade
sensibilidade = print(TP / (TP + FN))
sensibilidade

0.9508196721311475

#especificidade
especificidade = print(TN / (TN + FP))
especificidade

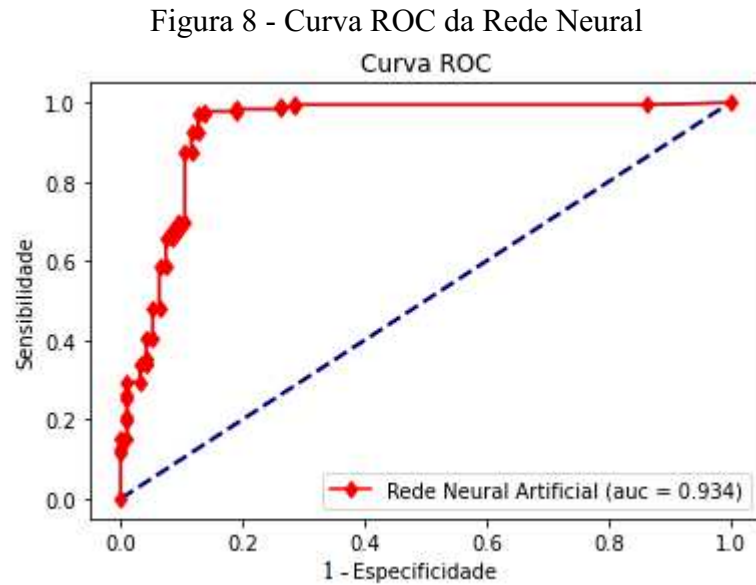
0.8736842105263158

#f1_score = 2 * (precisao*sensibilidade) / (precisao+sensibilidade)
f1_score = 2 * (0.9470*0.9306) / (0.9470+0.9306)
f1_score

0.9387283766510438
```

Fonte: Autor

A métrica encontrada após a criação da curva ROC, na figura 8, isto é, a área abaixo da curva (AUC) = 0.934, mediu a capacidade do modelo de prever uma pontuação maior de exemplos positivos em comparação com os exemplos negativos.



Fonte: Autor

Na pesquisa foram aplicadas as Redes Neurais Artificiais (RNA), apresentadas por sistemas de neurônios interconectados, que computam valores de saída, simulando o comportamento das redes neurais biológicas. Como forma de comparação de resultados a outros algoritmos utilizados em Aprendizado de Máquina, foram selecionados e aplicados outros três algoritmos ao conjunto de dados: **Máquina de Vetor de Suporte** (SVM), que busca encontrar uma linha de separação entre as classes, e calcular as distâncias entre os pontos. Para ele, os melhores valores dos parâmetros definidos pelo GridSearch foram ‘C’:1000, ‘gamma’:0.0001 e ‘kernel’:’rbf’; **Random Forest**, que faz uma combinação de árvores de decisão, ou seja, um mapa de possíveis resultados de uma série de escolhas relacionadas. Nele, foram estimadas 200 árvores aleatórias no classificador; **K-Nearest Neighbors** (KNN), que determina a qual grupo a amostra vai pertencer com base em amostras vizinhas, sendo utilizados os dois resultados com menor taxa de erro, ou seja, duas variáveis de controle (K). Para fins de resultado, esses três algoritmos foram aplicados ao conjunto de dados e os valores, estão contidos na tabela 3.

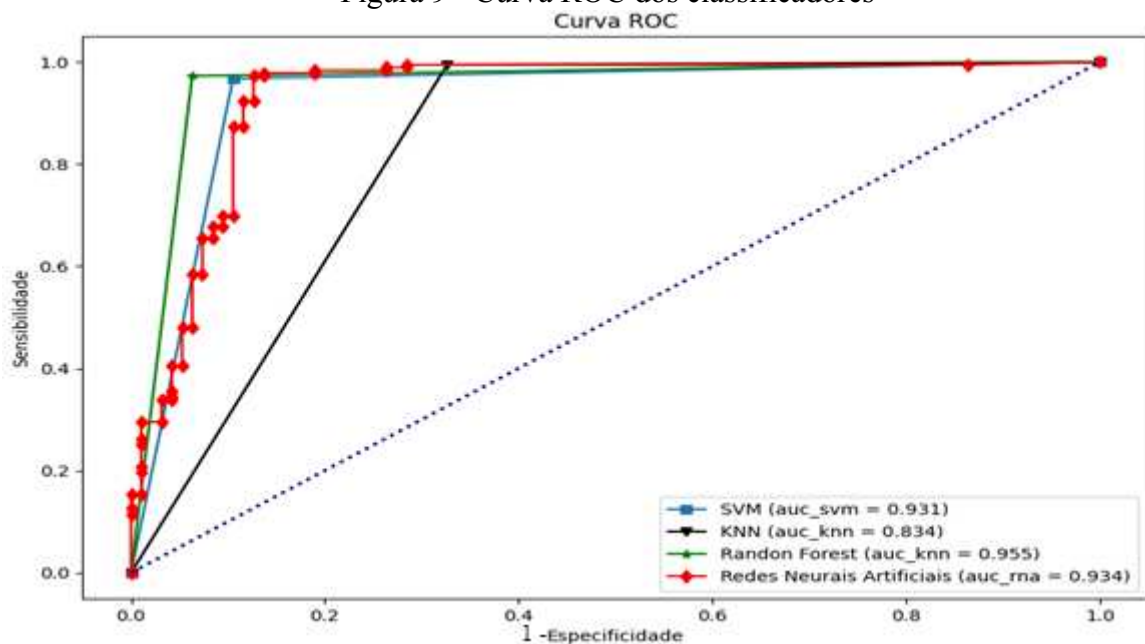
Tabela 3 - Avaliação dos algoritmos

Algoritmos/Métricas	Acurácia	Precisão	Sensibilidade	F1_Score
RNA	0.92	0.93	0.95	0.93
SVM	0.94	0.94	0.93	0.94
Random Forest	0.96	0.96	0.95	0.96
KNN (k=26)	0.88	0.92	0.83	0.88
KNN (k=25)	0.87	0.92	0.82	0.88

Fonte: Autor

Em uma das execuções dos classificadores, o gráfico da curva ROC-AUC foi gerado da seguinte forma:

Figura 9 - Curva ROC dos classificadores



Fonte: Autor

Portanto, a partir das métricas matriz de confusão e validação cruzada pode-se afirmar que o modelo apresenta um bom desempenho e uma boa capacidade de generalização. Além disso, algoritmos menos complexos podem ser aplicados na resolução do problema da pesquisa.

5 DISCUSSÃO

A análise exploratória do conjunto de dados trouxe a visão geral da tipologia e evolução dos pacientes atendidos pelo serviço de fisioterapia, comparando avaliação e saída hospitalar. Foram coletados dados valiosos ao serviço, porém a discussão envolve o desenvolvimento do modelo de Aprendizado de Máquina, seus resultados aplicações na área da saúde.

A análise preditiva foi realizada, a partir do desenvolvimento de um modelo de Aprendizado de Máquina, para avaliar os resultados obtidos. Toda a construção do modelo, baseada em redes neurais artificiais, foi discutida desde o compartilhamento dos dados até a métrica de avaliação do modelo. O conjunto de dados foi composto por 22 atributos de avaliação hospitalar da capacidade física, mobilidade e função respiratória, com 1.386 registros.

Para a aplicação do modelo, foram definidos os previsores e a classe “EMU na alta” como desfecho, classificando o paciente em independente ou não. O modelo foi criado em uma rede neural binária multicamadas, sendo que a aplicação do classificador foi avaliada pela acurácia entre os previsores e a classe do conjunto de teste, através da validação cruzada, alcançando nesse experimento 93,21% de acurácia.

A segunda métrica utilizada para medir o desempenho do modelo foi a matriz de confusão, que chegou ao resultado de acurácia de 92.44%. Além disso, alcançou uma precisão de 93,54%, sensibilidade de 95,08%, especificidade de 87,36% e o F1_score foi de 0,9387.

A pesquisa foi aplicada em redes neurais artificiais e comparada a três outros algoritmos, isto é, SVM, Random Forest e o KNN. A partir dos resultados obtidos, percebeu-se que o problema de pesquisa poderia ser respondido por um algoritmo menos complexo que as redes neurais artificiais.

Dentre os algoritmos de inteligência artificial, o modelo de Sanchez-Montanes et al. (2020) teve por objetivo a detecção precoce do diagnóstico de COVID-19, através do aprendizado de máquina supervisionado com regressão logística, atingindo a sensibilidade de 81,69% e uma especificidade de 81,46%.

No trabalho de Iwamoto et al. (2020), com o objetivo de predição de dependência das atividades de vida diária em pacientes com AVC, sendo utilizada a medida de independência funcional (MIF), o algoritmo de árvore de decisão alcançou 83% de precisão.

Kruse et al. (2018) aplicaram o Aprendizado de Máquina pelo algoritmo de regressão linear bayesiano, após o internamento hospitalar de idosos belgas, para prever a mortalidade em 5 anos e imobilidade em 3 anos, alcançando 85% de precisão para a previsão de mortalidade em 5 anos e 74% de precisão para a imobilidade em 3 anos.

O estudo Lin et al. (2020) através de uma rede neural, desenvolveu uma forma abreviada da escala motora de Fugl-Meyer, que é usada para avaliação de pessoas com AVC, que dispõe de 50 itens, sendo que ao final os autores criaram um modelo com 10 itens que comprova sua eficiência.

Dentre as aplicações das redes neurais voltadas aos tratamentos em saúde, Prabhu, O'Connor e Moran (2020) estudando a reabilitação cardíaca baseada em exercícios, concluíram com base na arquitetura AlexNet, que as redes neurais possuem um desempenho para o reconhecimento de exercícios melhor que as abordagens tradicionais, com pontuação no score F1 de 97.18%.

O estudo de Yin et al. (2019) cita que as redes neurais artificiais já possuem um longo histórico, porém são subutilizadas na reabilitação, sendo úteis na checagem de diagnósticos e prognósticos, porém não substituem o especialista. No estudo desenvolvido no tratamento da fascite plantar com a terapia por ondas de choque, encontraram um modelo confiável com uma precisão geral de 92,5%, melhor que um estudo anterior com uso de regressão logística.

Segundo Belliveau et al. (2016), os modelos de redes neurais superaram os modelos de regressão logística com nível maior de 85% de precisão e AUC entre 0.86 e 0.90 para prever deambulação após um ano de alta hospitalar. Já a precisão da independência modificada e dependência de outra pessoa, atingiram entre 76-86%, com AUC entre 0.70 e 0.82. Para os autores, os modelos preditivos podem apoiar o julgamento clínico reduzindo os níveis de incertezas durante a fase inicial de reabilitação, fornecendo estimativas individualizadas sobre a probabilidade dos diversos resultados funcionais e recomendações para reabilitação.

Ozdemir et al. (2020) estudaram o diabetes mellitus (DM) utilizando as redes neurais para detectar as condições associadas nos estágios iniciais, com os parâmetros de entrada

idade, sexo, duração da doença e hemoglobina glicada e nível da neuropatia, dor neuropática e cinesiofobia como parâmetros de saída. Os autores encontraram na avaliação do modelo 0,99 como resposta ao valor da área sob a curva (AUC), concluindo que modelos de redes neurais também são eficazes no gerenciamento de complicações e distúrbios de movimento, sendo importantes na colaboração de tomada de decisões.

Kaczmarczyk, Wit, Krawczyk e Zaborski (2009) estudaram a marcha em pacientes pós-AVC, através da modelagem em redes neurais do tipo perceptron multicamadas, onde os valores de entrada eram valores discretos dos ângulos nos quadris e joelhos, e três saídas com os tipos de marcha equina (ante-pé), plana (chato) e vara (calcanhar). Os autores concluíram que a análise por redes neurais foi superior aos outros métodos analíticos. Para o quadril no plano sagital, o melhor acerto foi de 97% para a marcha com o pé chato e no plano frontal, 95% de acerto para o padrão pé chato e varo e 85% para o padrão equino.

O estudo de Isik e Arslan (2011) descreveu e avaliou uma rede neural artificial, que identificou no ultrassom Doppler, micro êmbolos cerebrais, vistos em tempo real. Os autores encontraram que a rede perceptron multicamadas, para classificar o normal e anormal em pacientes com doença arterial, foi superior ao classificador Bayesiano. O experimento atingiu a acurácia em 95% nos homens e 97% nas mulheres.

Na aplicação de Johnsson et al. (2020) o objetivo era investigar uma rede neural artificial para detectar as dependências entre as variáveis clínicas disponíveis na admissão hospitalar e realizar previsões do resultado funcional. A rede neural apresentou uma boa capacidade de prever o resultado em 6 meses, com AUC de 0.852 na validação cruzada e 0.891 no conjunto de validação interna independente. Ao comparar o desempenho, a rede neural mostrou um desempenho significativamente melhor que o escore de risco comumente utilizado, assim como a regressão logística.

6 CONSIDERAÇÕES FINAIS

O estudo pretendeu criar e aplicar um modelo de aprendizado de máquina, a partir de um conjunto de dados do serviço de fisioterapia de um hospital de ensino, que previsse o desfecho funcional em sair do hospital com independência física, ou seja, capacidade de realizar as atividades como a deambulação sem auxílio, ou a manutenção da dependência de outras pessoas, como o uso de cadeira de rodas para locomoção.

A partir da base de dados histórica com atributos da avaliação fisioterapêutica, durante o ano de 2020 nas enfermarias clínicas, foi criado um modelo de rede neural artificial. Após a aplicação do modelo e com resultados dos testes, foram avaliados pelas métricas matriz de confusão e validação cruzada, podendo-se afirmar que o modelo apresentou um bom desempenho e uma boa capacidade de generalização, com a possibilidade que prever o desfecho da independência funcional.

Como limitações a serem exploradas em próximos estudos, tem-se o limitado tamanho da amostra, que pode ter melhor desempenho com a ampliação do conjunto de dados. Dados faltantes na planilha é outro fator limitante que pode afetar a capacidade de modelo em prever ocorrências e equívocos na avaliação do perfil dos pacientes atendidos. Há necessidade de ser reavaliado o aprimoramento dos atributos para previsão de Aprendizado de Máquina, voltado para a fisioterapia motora e também respiratória, com a possibilidade da inclusão de novas escalas. E por fim, faz-se necessário a padronização no preenchimento das células, pois é comum o uso de numerais e letras para o mesmo atributo.

O estudo nos permite inferir a alta capacidade de resultados que a informática em saúde pode trazer as diversas áreas do conhecimento voltadas diretamente à atenção dos pacientes. No serviço de fisioterapia, a predição pode contribuir para maior precisão nas avaliações, avanço em melhores métodos de tratamento, intervenções direcionadas, maior agilidade de enfrentamento aos diagnósticos, rapidez para encaminhamento as especialidades e redução do tempo e custo na reabilitação.

7 REFERÊNCIAS

- ABATE, D. T. Influência da Fisioterapia na Síndrome do Imobilismo. **Revista Unoeste**, 2013. Disponível em: <http://revistas.unoeste.br/revistas/ojs/index.php/cv/article/viewFile/874/1035>. Acesso em: mar. 2021.
- ADLER, J; MALONE, D. Early mobilization in the intensive care unit: a systematic review. **Cardiopulm Phys Ther J**. 23(1): p. 5-13, mar. 2012. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3286494>. Acesso em: fev. 2021.
- AGARTIGLU, K. G; YILMAZ, M; SOZMEN, M. K. Determination of the costs of falls in the older people according to the decision tree model. **Arch Gerontol Geriatr**. 87:104007. Mar, 2020. DOI: <https://doi.org/10.1016/j.archger.2019.104007>.
- ALLEN, C; GLASZIOU, P; DEL MAR, C. Bed rest: a potentially harmful treatment needing more careful evaluation. **Lancet**. 354(9186), p. 1229–33, out. 1999. DOI: [https://doi.org/10.1016/s0140-6736\(98\)10063-6](https://doi.org/10.1016/s0140-6736(98)10063-6).
- ANJOS, F. R, et al. Probabilidade de cair e medo de quedas após oficina de equilíbrio em idosos praticantes de atividade física. **Revista de Atenção à Saúde**. 13(44), p. 5-10, 2015. Disponível em: https://seer.uscs.edu.br/index.php/revista_ciencias_saude/article/view/2725. Acesso em: abril. 2021.
- BAGSHAW, S. M. et al. Long-term association between frailty and health-related quality of life among survivors of critical illness: a prospective multicenter cohort study. **Crit Care Med**. 43(5). p. 973–82, may, 2015. DOI: <https://doi.org/10.1097/ccm.0000000000000860>.
- BALDWIN, M. R. et al. The feasibility of measuring frailty to predict disability and mortality in older medical intensive care unit survivors. **J Crit Care**. 29(3). p. 401-8, 2014. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4012557/> . Acesso em: maio. 2021.
- BARBIERI, D; ZACCAGNI, L. Strength training by children and adolescents. **ACSM**. Indianapolis, 2013. DOI: <https://doi.org/10.1542/peds.2007-3790>.
- BASMAJIAN, J. V. **Biofeedback: principles and practice for clinicians**. 3^oed. Williams & Wilkins, Baltimore, 1989.
- BEDNARIK, J. et al. Risk factors for critical illness polyneuromyopathy. **J Neurol**. 252(3), p. 343–51, mar. 2005. DOI: <https://doi.org/10.1007/s00415-005-0654-x>.
- BEHM, D. G. et al. Effectiveness of traditional strength vs. power training on muscle strength, power and speed with youth: a systematic review and meta-analysis. **Front Physiol**. 8, 423, 2017. DOI: <https://dx.doi.org/10.3389%2Ffphys.2017.00423>.
- BELLIVEAU, T, et al. Developing Artificial Neural Network Models to Predict Functioning One Year After Traumatic Spinal Cord Injury. **Arch Phys Med Rehabil**. 97(10). p. 1663-1668, oct. 2016. DOI: <https://doi.org/10.1016/j.apmr.2016.04.014>.

BERNEY, S. C. et al. Intensive care unit mobility practices in Australia and New Zeland: a point prevalence study. **Crit Care Resusc.** 15(4). p. 260–5, 2013. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/24289506/>. Acesso em: feV. 2021

BIERBRAUER, J. et al. Early type II fiber atrophy in intensive care unit patients with nonexcitable muscle membrane. **Crit Care Med.** 40(2). p. 647-50, fev. 2012. Disponível em: https://journals.lww.com/ccmjournal/Fulltext/2012/02000/Early_type_II_fiber_atrophy_in_intensive_care_unit.38.aspx. Acesso em: mar. 2021

BRAUN, A. et al. Association of low serum 25-hydroxyvitamin D levels and mortality in the critically ill. **Crit Care Med.** 39(4). p. 671–7, April, 2011. DOI: <https://dx.doi.org/10.1097/CCM.0b013e318206ccdf>.

BURNS, D. M. et al. Shoulder physiotherapy exercise recognition: machine learning the inertial signals from a smartwatch. **Physiological measurement**, v. 39, n. 7, p. 075007, 2018. DOI: [10.1088/1361-6579/aacfd9](https://doi.org/10.1088/1361-6579/aacfd9).

CAMILA, D. et al. Functional ability in younger and older elderlies after discharge from the intensive care unit. A prospective cohort. **Rev Bras Ter Intensiva.** 29(3):293–302, jul-sep, 2017. DOI: <https://doi.org/10.5935/0103-507X.20170055>.

CANEVELLI, M. et al. Promoting the assessment of frailty in the clinical approach to cognitive disorders. **Frontiers in Aging Neuroscience.** 36(9), 2017. Disponível em: <https://dx.doi.org/10.3389%2Ffnagi.2017.00036>.

CAO, J. et al. Factors associated with death in bedridden patients in China: A longitudinal study. **PLoS One.** 15(1), jan. 2020. Disponível em: <https://doi.org/10.1371/journal.pone.0228423>.

CAO J; WANG, M; LI, Y; ZHANG, Q. Improved support vector machine classification algorithm based on adaptive feature weight updating in the Hadoop cluster environment. **PLoS One.** 14(4), 2019. DOI: <https://doi.org/10.1371/journal.pone.0215136>

CARVALHO, V. L; OLIVEIRA, A. L. C. Interface entre a saúde coletiva e a fisioterapia: avaliação da política educacional. **Fisioterapia Brasil.** 17(4). p.428-34. 2016. DOI: <https://doi.org/10.33233/fb.v17i4.515>.

CHANG, S. S; WEISS, C. O; XUE, Q. L; FRIED, L. P. Association between inflammatory-related disease burden and frailty: results from the Women's Health and Aging Studies (WHAS) I and II. **Ary Gerontol Geriatr.** 54(1). p. 9–15, 2012. DOI: <https://dx.doi.org/10.1016%2Fj.archger.2011.05.020>.

CHING, T. et al. Opportunities and obstacles for deep learning in biology and medicine. **J. R. Soc. Interface.** 15, 2018. DOI: <https://doi.org/10.1098/rsif.2017.0387>.

CLEGG, A. et al. Frailty in elderly people. **Lancet.** 381(9868). p.752-62. 2013. Disponível em: <https://royalsocietypublishing.org/doi/10.1098/rsif.2017.0387>. Acesso em: mar. 2021.

COFFITO. **Conselho Federal de Fisioterapia e Terapia Ocupacional**. Disponível: https://www.coffito.gov.br/nsite/?page_id=2339. Acesso: fev.2021.

COMPSTON, A. Aids to the investigation of peripheral nerve injuries. Medical Research Council: Nerve Injuries Research Committee. His Majesty's Stationery Office: 1942. **Brain**. 133(10). p. 2838–44, 2010. DOI: <https://doi.org/10.1093/brain/awq270>.

CONCEIÇÃO, L. S. R. et al. Perfil epidemiológico dos pacientes atendidos pela fisioterapia do Hospital da Universidade Federal de Sergipe. **Interfaces Científicas-Saúde e Ambiente**, v. 3, n. 1, p. 29-38, 2014. Disponível em: <https://periodicos.set.edu.br/saude/article/view/1533>. Acesso em: jan. 2021.

COOK, C; COOK, A; WORRELL, T. Manual therapy provided by physical therapists in a hospital-based setting: a retrospective analysis. **Journal of manipulative and physiological therapeutics**, v. 31, n. 5, p. 338-343, 2008. DOI: 10.1016/j.jmpt.2008.04.005.

COSTA, F. M. et al. Avaliação da funcionalidade motora em pacientes com tempo prolongado de internação hospitalar. **UNOPAR Cient Ciênc Biol Saúde**. 16(2). p. 87-91, 2014. Disponível em: <https://revista.pgskroton.com/index.php/JHealthSci/article/view/486>. Acesso em: jan. 2021.

COTT, P. et al. Learning health systems need to bridge the ‘two cultures’ of clinical informatics and data science. **Journal of Innovation in Health Informatics**. 25(2). p. 126-131, 2018. DOI: <https://doi.org/10.14236/jhi.v25i2.1062>.

CREFITO-10. **Conselho Regional de Fisioterapia e Terapia Ocupacional da 10º Região**. Disponível em: <http://www.crefito10.org.br/interna.jsp?a=profissional#>. Acesso: fev. 2021.

CREFITO-3. **Conselho Regional de Fisioterapia e Terapia Ocupacional da 3º Região**. Disponível em: <http://www.crefito3.org.br/dsn/fisioterapia.asp>. Acesso: fev/2021.

CULYER, A. J. Health Economics and Health Technology Assessment. **Health Economics and sustainable medicine**. 46 (7), 2018. Disponível em: <https://doi.org/10.1016/j.mpmmed.2018.04.002>. Acesso em: abril. 2021.

CUPANI, A. Filosofia da tecnologia: um convite. Florianópolis, SC: **Editora UFSC**, 2011.

CURTIS, J. P. et al. The obesity paradox: body mass index and outcomes in patients with heart failure. **Arch Intern Med**. 165(1). p. 55-61, jan. 2005. Disponível em: <https://jamanetwork.com/journals/jamainternalmedicine/fullarticle/486350>. Acesso em: abril. 2021.

DELOUILLE, V. et al. Coronal holes detection using supervised classification. In: Machine learning techniques for space weather. **Elsevier**, p. 365-395, 2018. DOI: <https://doi.org/10.1016/B978-0-12-811788-0.00015-9>.

DENEHY, L. et al. A physical function test for use in the intensive care unit: validity, responsiveness, and predictive utility of the physical function ICU Test (Scored). **Phys Ther**. 93(12). p. 1636–45, 2013. DOI: <https://doi.org/10.2522/ptj.20120310>.

DESCHENES, M. R. Effects of aging on muscle fibre type and size. **Sports Medicine**. 34(12). p. 809–24, fev. 2004. Disponível em: <https://link.springer.com/article/10.2165/00007256-200434120-00002>. Acesso em: fev. 2021.

DING, J; JOHNSON, C. E; LEE, Y. C. O; GAZEY, A; COOK, A. Characteristics of People with Dementia vs Other Conditions on Admission to Inpatient Palliative Care. **J Am Geriatr Soc**. 68(8). p. 1825-1833, aug. 2020. DOI: <https://doi.org/10.1111/jgs.16458>.

DIRKS, M. L. et al. One week of bed rest leads to substantial muscle atrophy and induces whole-body insulin resistance in the absence of skeletal muscle lipid accumulation. **Diabetes**. 65(10). p. 2862–75, 2016. DOI: <https://doi.org/10.2337/db15-1661>.

DOS REIS ALMEIDA, A. C. F. et al. Impacto de uma rotina de atendimentos fisioterapêuticos baseado em níveis de prioridade em uma unidade de neurocirurgia de um hospital público. **Revista Neurociências**. v. 27. p. 1-14, 2019. Disponível em: <https://periodicos.unifesp.br/index.php/neurociencias/article/view/9636/7333>. Acesso em: fev. 2021.

FALAVIGNA, G. et al. Artificial neural networks and risk stratification in emergency departments. **Intern Emerg Med**. 14(2). p. 291-299, mar. 2019. DOI: <https://doi.org/10.1007/s11739-018-1971-2>.

FEHR, L; LANGBEIN, W. E; SKAAR, S. B. Adequacy of power wheelchair control interfaces for persons with severe disabilities: a clinical survey. **J Rehabil Res Dev**. 37(3) p. 353-60, may-jun, 2000. Disponível em: <https://www.rehab.research.va.gov/jour/00/37/3/pdf/Fehr.pdf>. Acesso em: março. 2021.

FERREIRA, J. et al. Atuação do Fisioterapeuta em enfermaria hospitalar no Brasil. **Fisioterapia Brasil**. V. 18, n. 6, 2017. DOI: <https://doi.org/10.33233/fb.v18i6.1055>.

FHON, J. R. S. et al. Prevalência de quedas em idosos em situação de fragilidade. **Rev Saúde Pública**. m47(2). p. 266–73. April, 2013. DOI: <https://doi.org/10.1590/S0034-8910.2013047003468>.

FRIED, L. P. et al. Cardiovascular Health Study Collaborative Research Group. Frailty in older adults: evidence for a phenotype. **J Gerontol A Biol Sci Med Sci**. 56A(3). p.146–56, 2001. DOI: <https://doi.org/10.1093/gerona/56.3.M146>.

FRIED, L.P; WALSTON, J. Frailty and failure to thrive. In: Hazzard WR, Blass JP, Ettinger Jr WH, Halter JB, Ouslander JB. **Principles of geriatric medicine and gerontology**. 4th ed. New York: McGraw-Hill Health Professions Divisions. p. 1387–402, 1998.

FRITZ, S. Sports & Exercise Massage-E-Book: Comprehensive Care in Athletics, Fitness, & Rehabilitation. **Elsevier Health Sciences**, 2012.

GARCIA, P. A. Sarcopenia, mobilidade funcional e nível de atividade física em idosos ativos da comunidade. [dissertação]. Belo Horizonte: **Universidade Federal de Minas Gerais**; 2008.

GARCÍA-MASSÓ, X. et al. Neural network for estimating energy expenditure in paraplegics from heart rate. **Int J Sports Med.** 35(12). p. 1037-43. nov, 2014. DOI: <https://doi.org/10.1055/s-0034-1368722>.

GILLEN, G; BURKHARDT, A. **Stroke rehabilitation: a functional-based approach.** St. Louis. Mosby. 2004.

GONÇALVES, A. C. S. Perfil clínico dos pacientes atendidos pelo serviço de fisioterapia na unidade de urgência e emergência de um hospital público de Minas Geravasconcelis. **ASSOBRAFIR Ciência.** 5(3). p. 55-62, 2014. Disponível em: <https://www.cpcjournal.org/article/5de00c870e882578204ce1d5>. Acesso em: mar. 2021.

HAN, J; PEI, J; KAMBER, M. **Data mining: concepts and techniques.** Elsevier, 2011.

HAYKIN, S. **Redes Neurais: Princípios e práticas.** Bookman. 2ºed, 2001.

HERMANS, G; VAN DEN BERGHE, G. Clinical review: Intensive care unit acquired weakness. **Crit Care.** 19:274. Aug, 2015. DOI: <https://dx.doi.org/10.1186%2Fs13054-015-0993-7>.

HERRIDGE, M. S. et al. Functional disability 5 years after acute respiratory distress syndrome. **N Engl J Med.** 364(14). p. 1293–304. Apr, 2011. DOI: <https://doi.org/10.1056/nejmoa1011802>.

HERRIDGE, M. S. et al. One-year outcomes in survivors of the acute respiratory distress syndrome. **N Engl J Med.** 348. p. 683–93, 2003. DOI: <https://doi.org/10.1056/nejmoa022450>.

HODGSON, C. L. et al. Expert consensus and recommendations on safety criteria for active mobilization of mechanically ventilated critically ill adults. **Critical Care.** 18(658). p. 1–9, 2014. DOI: <https://doi.org/10.1186/s13054-014-0658-y>.

HOFFMANN, R; BRODOWSKI, H; STEINHAGE, A; GRZEGORZEK, M. Detecting Walking Challenges in Gait Patterns Using a Capacitive Sensor Floor and Recurrent Neural Networks. **Sensors (Basel).** 21(4). p. 1086. fev, 2021. DOI: <https://dx.doi.org/10.3390%2Fs21041086>.

HUANG, S. et. al. Applications of Support Vector Machine (SVM) Learning in Cancer Genomics. **Cancer Genomics Proteomics.** 15(1), p. 41-51. Jan, 2018. DOI: <https://dx.doi.org/10.21873%2Fcgp.20063>.

ISHIZUKA, M. A. Tradução para o português e validação do teste POMA II “Performance-Oriented Mobility Assessment II” [tese]. São Paulo (SP): **Universidade de São Paulo**, 2008. Disponível em: <https://www.teses.usp.br/teses/disponiveis/5/5144/tde-12012009-142854/pt-br.php>. Acesso em: jan. 2021.

IŞIK, H; ARSLAN, S. An Artificial Neural Network classification approach for use the ultrasound in physiotherapy. **J Med Syst.** 35(6). p. 1333-41. Dec, 2011. DOI: <https://doi.org/10.1007/s10916-009-9410-6>.

IWAMOTO, Y. et al. Development and Validation of Machine Learning-Based Prediction for Dependence in the Activities of Daily Living after Stroke Inpatient Rehabilitation: A Decision-Tree Analysis. **J Stroke Cerebrovasc Dis.** 29(12). p. 105332. Dec, 2020. DOI: <https://doi.org/10.1016/j.jstrokecerebrovasdis.2020.105332>.

JOHNSSON, J. et al. Artificial neural networks improve early outcome prediction and risk classification in out-of-hospital cardiac arrest patients admitted to intensive care. **Crit Care.** 24(1). p. 474. jul, 2020. DOI: <https://doi.org/10.1186/s13054-020-03103-1>.

KACZMARCZYK, K; WIT, A; KRAWCZYK, M; ZABORSKI, J. Gait classification in post-stroke patients using artificial neural networks. **Gait Posture.** 30(2) p. 207-10. Aug, 2009. DOI: <https://doi.org/10.1016/j.gaitpost.2009.04.010>.

KARUKA, A. H; SILVA, J. M. G; NAVEGA, M. T. Análise da concordância entre instrumentos de avaliação do equilíbrio corporal em idosos. **Rev Bras Fisioter.** 15(6). p. 460–6, 2011. DOI: <https://doi.org/10.1590/S1413-35552011000600006>.

KAWAKAMI, D. M. O. et al. T. Perfil epidemiológico e atuação fisioterápica em pacientes hospitalizados – análise retrospectiva. **Colloquium Vitae.** vol. 10, n. 5, p. 95-103. Jul–Dez, 2018.

KHAKI, S; WANG, L; ARCHONTOULIS, S. V. A CNN-RNN Framework for Crop Yield Prediction. **Front Plant Sci.** 10:1750. Jan, 2020. DOI: <https://dx.doi.org/10.3389%2Ffpls.2019.01750>.

KOCK, K. S. et al. Adequações dos dispositivos de oxigenoterapia em enfermaria hospitalar avaliadas por oximetria de pulso e gasometria arterial. **ASSOBRAFIR Ciência.** 5(1). p. 53-64, 2014. Disponível em: <https://assobrafirciencia.org/journal/assobrafir/article/5de016f70e8825fe404ce1d5>. Acesso em: fev. 2021.

KRUSE, C et al. Predicting mortality and incident immobility in older Belgian men by characteristics related to sarcopenia and frailty. **Osteoporos Int.** 29(6) p. 1437-1445. jun, 2018. DOI: <https://doi.org/10.1007/s00198-018-4467-z>.

LANG, P. O; MICHEL, J. P; ZEKRY, A. Frailty syndrome: a transitional state in a dynamic process. **Gerontology.** 55(5). p. 539–49, 2009. DOI: <https://doi.org/10.1159/000211949>.

LATORRE-ROMÁN, P. A. et al. Handgrip strength test as a complementary tool in monitoring asthma in daily clinical practice in children. **Iran J Allergy Asthma Immunol.** 13(6). p. 396-403, 2014. Disponível em: <https://ijaai.tums.ac.ir/index.php/ijaai/article/view/427>. Acesso em: fev. 2021.

LECUN, Y; BENGIO, Y; HINTON, G. Deep learning. **Nature.** 521(7553). p. 436-44. May, 2015. DIU: <https://doi.org/10.1038/nature14539>.

LEE, J. Y; STYCZYNSKI, M. P. NS-kNN: a modified k-nearest neighbors approach for imputing metabolomics data. **Metabolomics**. 14(12), 2018. DOI: <https://doi.org/10.1007/s11306-018-1451-8>.

LEVINE, S. A; LOWN, B. "Armchair" treatment of acute coronary thrombosis. **J Am Med Assoc**. 148(16). p. 1365–9, 1952. Disponível em: <https://jamanetwork.com/journals/jama/article-abstract/314521>. Acesso em: fev. 2021.

LEWIS-KRAUS, G. The Great AI Awakening. **The New York Times Magazine**, 2016. Disponível em: <https://www.nytimes.com/2016/12/14/magazine/the-great-ai-awakening.html>. Acesso em: abril. 2021.

LI, J. et al. A multicenter random forest model for effective prognosis prediction in collaborative clinical research network. **Artif Intell Med**. 103:101814. Mar, 2020. DOI: <https://doi.org/10.1016/j.artmed.2020.101814>.

LIAO, Y; VAKANSKI, A; XIAN, M. A Deep Learning Framework for Assessing Physical Rehabilitation Exercises. **IEEE Trans Neural Syst Rehabil Eng**. 28(2). p. 468-477. fev. 2020. DOI: <https://doi.org/10.1109/TNSRE.2020.2966249>.

LIN, G.H. et al. A 10-item Fugl-Meyer Motor Scale Based on Machine Learning. **Phys Ther**. Jan, 2021. Apr 4;101(4):pzab036. DOI: <https://doi.org/10.1093/ptj/pzab036>.

LIPSHUTZ, A. K; GROPPER, M. A. Acquired neuromuscular weakness and early mobilization in the intensive care unit. **Anesthesiology**. 118(1). p. 202-15. jan. 2013. DOI: <https://doi.org/10.1097/aln.0b013e31826be693>.

LONG, Y; WANG, L; SUN, M. Structure Extension of Tree-Augmented Naive Bayes. **Entropy (Basel)**. 21(8). P. 721. Jul, 2019. DOI: <https://dx.doi.org/10.3390%2Fe21080721>.

LUNDY-EKMAN, L. **Neuroscience: fundamentals for rehabilitation**. St. Louis: Saunders; 2007.

MARAGATHAM, G; DEVI, S. LSTM Model for Prediction of Heart Failure in Big Data. **J Med Syst**. 43(5), 111. Mar, 2019. DOI: <https://doi.org/10.1007/s10916-019-1243-3>.

MARTINEZ, B. P. et al. Viabilidade do teste de velocidade de marcha em idosos hospitalizados. **J Bras Pneumol**. 42(3). p. 196-202, 2016. DOI: <http://dx.doi.org/10.1590/S1806-37562015000000058>.

MAZO, G. Z; Liposcki, D.B; Ananda, C; Preve, D. Condições de saúde, incidência de quedas e nível de atividade física dos idosos. **Rev Bras Fisioter**. 11(6). p. 437–42. nov. 2007. DOI: <https://doi.org/10.1590/S1413-35552007000600004>.

MENDES, G. S. C. V; DE SORDI, M. R. L. Metodologia de avaliação de implementação de programas e políticas públicas. **EccoS – Revista Científica**, n. 30, p. 93-112, 2013. DOI: <https://doi.org/10.5585/eccos.n30.3697>.

MIJNARENDS, D. M. et al. Instruments to assess sarcopenia and physical frailty in older people living in a community (care) setting: similarities and discrepancies. **J Am Med Dir Assoc.** 16(4). p. 301–8. April. 2015. DOI: <https://doi.org/10.1016/j.jamda.2014.11.011>.

MIMIC-EXTRACT. **A Data Extraction, Preprocessing, and Representation Pipeline for MIMIC-III.** New York: ACM. April, 2020. DOI: <https://doi.org/10.1145/3368555.3384469>.

MITCHELL, T. M. Does machine learning really work?. **AI magazine**, v. 18, n. 3, p. 11-11, 1997. DOI: <https://doi.org/10.1609/aimag.v18i3.1303>.

MIRANDA, H. A. A. A. Correlação entre Funcionalidade, Mobilidade e Risco de Quedas em Idosos com Doença de Alzheimer. Dissertação; **UNB**. Brasília, 2014. Disponível em: <http://repositorio.unb.br/handle/10482/18402>. Acesso em: abril. 2021.

MORRIS, P. E. et al. Early intensive care unit mobility therapy in the treatment of acute respiratory failure. **Crit Care Med.** 36(8). p. 2238-43, 2008. DOI: <https://doi.org/10.1097/ccm.0b013e318180b90e>.

MÜLLER, D. V. K; TAVARES, G. M. S; SCHNEIDER, R. H. Análise do equilíbrio corporal em idosos classificados em diferentes faixas etárias através da posturografia dinâmica computadorizada (PDC). **Rev Kairós Gerontol.** 19(Esp 22). p. 61–83, 2016.

MUNDY, L. M. et al. Early mobilization of patients hospitalized with community-acquired pneumonia. **Chest.** 124(3). p. 883-9, 2003. DOI: <https://doi.org/10.1378/chest.124.3.883>.

MUNERA, E. et al. Integrating Smart Resources in ROS-based systems to distribute services. **ADCAIJ: Advances in Distributed Computing and Artificial Intelligence Journal** (ISSN: 2255-2863). **Salamanca**, v. 6, n. 1, 2017. DOI: <https://doi.org/10.14201/ADCAIJ2017611319>.

NATIONAL INSTITUTES OF HEALTH et al. NIH strategic plan for data science. **NIH**. Jun, 2018. Disponível em: https://datascience.nih.gov/sites/default/files/nih_strategic_plan_for_data_science_final_508.pdf. Acesso em: abril. 2021.

NATIONAL STROKE FOUNDATION. Clinical guidelines for stroke management 2010. Melbourne: **National Stroke Foundation**. 2010. Disponível em: https://www.pedro.org.au/wp-content/uploads/CPG_stroke.pdf. Acesso em: fev. 2021.

NEEDHAM, D. M. et al. Early physical medicine and rehabilitation for patients with acute respiratory failure: a quality improvement project. **Arch Phys Med Rehabil.** 91(4). p. 536–42. April, 2010. DOI: <https://doi.org/10.1016/j.apmr.2010.01.002>.

NORVIG, P; RUSSEL, S. **Inteligência Artificial**. Elsevier. 2ºed, 2004.

NUNES, N. M. et al. Avaliação do medo de cair e equilíbrio de idosos ativos e não ativos: um estudo comparativo. **Rev bras Ci e Mov.** 24(2). p. 173-81, 2016. Disponível em:

<http://cev.org.br/biblioteca/avaliacao-do-medo-de-cair-e-equilibrio-de-idosos-ativos-e-nao-ativos-um-estudo-comparativo/>. Acesso em: fev. 2021.

NYDAHL, P. et al. Early mobilization of mechanically ventilated patients: a 1-day point-prevalence study in Germany. **Crit Care Med.** 42(5). p. 1178–86, 2014. DOI: <https://doi.org/10.1097/ccm.000000000000149>.

NYDAHL, P. et al. Safety of patient mobilization and rehabilitation in the intensive care unit. Systematic review with meta-analysis. **Ann Am Thorac Soc.** 14(5). p. 766–77, 2017. DOI: <https://doi.org/10.1513/annalsats.201611-843sr>.

OGAWA, K. Y. L. et al. Intervenção fisioterapêutica nas emergências cardiorrespiratórias. **O Mundo da Saúde.** V. 33, n. 4. p. 457-66, 2009. Disponível em: http://www.saocamilo-sp.br/pdf/mundo_saude/70/457a466.pdf. Acesso em: mar. 2021.

OKOSHI, M. P; ROMEIRO, F. G; PAIVA, A. R; OKOSHI, K. Caquexia associada à insuficiência cardíaca. **Arq Bras Cardiol.** 100(5). p. 476-82, 2013. DOI: <https://doi.org/10.5935/abc.20130060>.

ORGANIZAÇÃO PANAMERICANA DE SAÚDE; ORGANIZAÇÃO MUNDIAL DA SAÚDE. **CIF: Classificação Internacional de Funcionalidade, Incapacidade e Saúde.** São Paulo: EDUSP; 2003.

OTTENBACHER, K. J; GRAHAM, J. E; FISHER, S. R. Data Science in Physical Medicine and Rehabilitation: Opportunities and Challenges. **Phys Med Rehabil Clin N Am.** 30(2). p. 459-471. May, 2019. DOI: <https://doi.org/10.1016/j.pmr.2018.12.003>.

OZDEMIR, F. et al. Prediction of neuropathy, neuropathic pain and kinesiophobia in patients with type 2 diabetes and design of computerized clinical decision support systems by using artificial intelligence. **Med Hypotheses.** 143:110070. Oct, 2020. DOI <https://doi.org/10.1016/j.mehy.2020.110070>.

PANDHARIPANDE, P. P. et al. Long-term cognitive impairment after critical illness. **N Engl J Med.** 369(14) p. 1306–16. Oct, 2013. DOI: <https://doi.org/10.1056/nejmc1313886>.

PARRY, S. M. et al. Functional outcomes in ICU –what should we be using? – an observational study. **Crit Care.** 19(1). p. 127, 2015. DOI: <https://dx.doi.org/10.1186%2Fs13054-015-0829-5>.

PASINA, L. et al. Risk factors for three-month mortality after discharge in a cohort of non-oncologic hospitalized elderly patients: Results from the REPOSI study. **Archives of gerontology and geriatrics,** v. 74, p. 169-173, 2018. DOI: 10.1016/j.archger.2017.10.016.

PERERA, S. et al. Gait speed predicts incident disability: a pooled analysis. **J Gerontol A Biol Sci Med Sci.** 71(1). p. 63–71. Jan, 2016. DOI: <https://doi.org/10.1093/gerona/glv126>.

PERME, C; CHANDRASHEKAR, R. Early mobility and walking program for patients in intensive care units: creating a standard of care. **Am J Crit Care.** 18(3). p. 212–21, 2009. DOI: <https://doi.org/10.4037/ajcc2009598>.

PERRY, J; BURNFIELD, J. M; CABICO, L. M. **Gait analysis: normal and pathological function**. Thorofare: Slack; 2010.

PIRES-NETO, R. C. et al. Early mobilization practice in a single brazilian intensive care unit. **J Crit Care**. 30(5). p. 896–900, 2015. DOI: <https://doi.org/10.1016/j.jcrc.2015.05.004>.

PISSOLATO, J. D. S; FLECK, C. S. Mobilização precoce na unidade de terapia intensiva adulta. **Fisioterapia Brasil**. V. 19, n. 3, 2018. Disponível em: <https://portalatlanticaeditora.com.br/index.php/fisioterapiabrasil/article/view/690>. Acesso em: mar. 2021.

POCINHO, R. et al. Internamentos prolongados numa Enfermaria de Medicina Interna. **Revista de Medicina Interna**. Vol. 26, n° 3, 2019. Disponível em: <https://1library.org/document/yjdjvr5y-internamentos-prolongados-numa-enfermaria-de-medicina-interna.html>. Acesso em: mar. 2021.

POLIT, D. F; BECK, C. T. Fundamentos de pesquisa em enfermagem: avaliação de evidências para a prática da enfermagem. **Artmed Editora**, 2011.

PRABHU, G; O'CONNOR, N. E; MORAN, K. Recognition and Repetition Counting for Local Muscular Endurance Exercises in Exercise-Based Rehabilitation: A Comparative Study Using Artificial Intelligence Models. **Sensors** (Basel). 20(17). Aug, 2020. DOI: <https://dx.doi.org/10.3390%2Fs20174791>.

PRZEDNOWEK, K. et al. Planning Training Loads for the 400 M Hurdles in Three-Month Mesocycles using Artificial Neural Networks. **J Hum Kinet**. 60. p, 175-189. Dec, 2017 DOI: <https://dx.doi.org/10.1515%2Fhukin-2017-0101>.

RABHI, Y; MRABET, M; FNAIECH, F. A facial expression controlled wheelchair for people with disabilities. **Comput Methods Programs Biomed**. 165. p, 89-105. Oct, 2018. DOI: <https://doi.org/10.1016/j.cmpb.2018.08.013>.

ROBLEDA, G. et al. Evaluation of pain during mobilization and endotracheal aspiration in critical patients. **Med Intensiva**. 40(2). p. 96–104, 2016. DOI: <https://doi.org/10.1016/j.medin.2015.03.004>.

ROCKWOOD, K. et al. A global clinical measure of fitness and frailty in elderly people. **CMAJ**. 173(5). p. 489–95. Aug, 2005. DOI: <https://doi.org/10.1503/cmaj.050051>.

ROCKWOOD, K. What would make a definition of frailty successful?. **Age Ageing**. 34(5). p. 432-4, 2005. DOI: <http://dx.doi.org/10.1093/ageing/afi146>.

RODEGHERO, J; COOK, C. The use of big data in manual physiotherapy. **Manual therapy**, v. 6, n. 19, p. 509-510, 2014. DOI: 10.1016/j.math.2014.10.014.

ROY, R; SIKDAR, D; MAHADEVAPPA, M; KUMAR, C. S. A fingertip force prediction model for grasp patterns characterised from the chaotic behaviour of EEG. **Med Biol Eng Comput**. 56(11). p. 2095-2107. Nov, 2018. DOI: <https://doi.org/10.1007/s11517-018-1833-0>.

RYDINGSWARD, J. E. et al. Functional status in ICU survivors and out of hospital outcomes: a cohort study. **Crit Care Med.** 44(5). p. 869–79, 2016. DOI: <https://dx.doi.org/10.1097%2FCCM.0000000000001627>.

SACHIN, P. et al. Musculoskeletal Physiotherapy using Artificial Intelligence and Machine Learning'. **International Journal of Innovative Science and Research Technology (IJISRT)**. Vol. 4, Issue. 11. p. 592-598, 2019. Disponível em: <https://ijisrt.com/assets/upload/files/IJISRT19NOV347.pdf>. Acesso em: fev. 2021.

SÁNCHEZ-MONTAÑÉS, M. et al. Machine Learning for Mortality Analysis in Patients with COVID-19. **Int J Environ Res Public Health.** 17(22). p. 8386. Nov, 2020. DOI: <https://dx.doi.org/10.3390%2Fijerph17228386>.

SANTOS, C. et al. Mechanisms of chronic muscle wasting and dysfunction after an intensive care unit stay: a pilot study. **Am J Respir Crit Care Med.** 194(7). p. 821–30. Oct, 2016. DOI: <https://doi.org/10.1164/rccm.201512-2344OC>.

SANTOS, L. S. P; COSTA, V. L. Perfil dos pacientes internados nas enfermarias adulto e pediátrica do Hospital Universitário de Lagarto. Monografia. **Universidade Federal de Sergipe**, Lagarto, 2018. Disponível em: <https://ri.ufs.br/handle/riufs/8886>. Acesso em: fev. 2021.

SANTOS, S. F. C; SILVA NETO, V. M. Treinamento resistido para idosos: Revisão de literatura. **Cinergis.** 18(2). p. 151-55, 2017. Disponível em: <https://online.unisc.br/seer/index.php/cinergis/article/view/8168>. Acesso em: mar. 2021.

SCARBOROUGH, J. E. et al. Combined mechanical and oral antibiotic bowel preparation reduces incisional surgical site infection and anastomotic leak rates after elective colorectal resection. **Annals of surgery,** v. 262, n. 2, p. 331-337, 2015. DOI: 10.1097/SLA.0000000000001041.

SCHWARTZ, M. S; ANDRASIK, F. **Biofeedback: A Practitioner's Guide.** 3rd ed. New York: Guilford Press; 2003.

SCHWEICKERT, W. D. et al. Early physical and occupational therapy in mechanically ventilated, critically ill patients: a randomised controlled trial. **Lancet.** 373(9678). p. 1874-82, 2009. DOI: [https://doi.org/10.1016/s0140-6736\(09\)60658-9](https://doi.org/10.1016/s0140-6736(09)60658-9).

SHTAR, G. et al. Using Machine Learning to Predict Rehabilitation Outcomes in Postacute Hip Fracture Patients. **Arch Phys Med Rehabil.** 102(3). p. 386-394. Mar, 2021. DOI: <https://doi.org/10.1016/j.apmr.2020.08.011>.

SHUMWAY-COOK, A; WOOLLACOTT, M. H. **Motor control: translating research into clinical practice.** 3rd ed. Philadelphia: Lippincott Williams & Wilkins; 2007.

SIBILLA, A. et al. Mobilization of mechanically ventilated patients in Switzerland. **J Intensive Care Med.** 35(1). p. 55-62. Jan, 2017. DOI: <https://doi.org/10.1177%2F0885066617728486>.

SICILIANO, G; SCHIRINZI, E; SIMONCINI, C; RICCI, G. Exercise therapy in muscle diseases: open issues and future perspectives. **Acta Myol.** 38(4). p. 233-238, 2019. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6955631> . Acesso em: fev. 2021.

SILVA, A. P. P; MAYNARD, K; CRUZ, M. R. Efeitos da Fisioterapia Motora em Pacientes Críticos: Revisão de Literatura. **Revista Brasileira de Terapia Intensiva.** V. 22, n. 1, p. 85-91, 2010. DOI: <https://doi.org/10.1590/S0103-507X2010000100014>.

SILVA, T. S. L, et al. Características clínicas de pacientes atendidos pela equipe de fisioterapia na enfermaria de um hospital de pequeno porte na região litoral norte do rio grande do sul. **ASSOBRAFIR Ciência,** 2020. Disponível em: <https://assobrafirciencia.org/article/doi/10.47066/2177-9333.AC.2020.0008>. Acesso em: mar. 2021.

SKINNER, E. H; BERNEY, S; WARRILLOW, S; DENEHY, L. Development of a physical function outcome measure (PFIT) and a pilot exercise training protocol for use in intensive care. **Crit Care Resusc.** 11(2). p. 110–5, 2009. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/19485874>. Acesso em: abril. 2021.

SOLDERA, C. L. C. Participação dos sistemas de manutenção do equilíbrio corporal, do risco de quedas e do medo de cair em idosos e longevos. [tese]. Porto Alegre (RS): **Pontifícia Universidade Católica do Rio Grande do Sul;** 2013. Disponível em: <http://tede2.pucrs.br/tede2/handle/tede/2717>. Acesso em: jan. 2021.

TACK, C. Artificial intelligence and machine learning: applications in musculoskeletal physiotherapy. **Musculoskelet Sci Pract.** 39. p. 164-169. Fev, 2019. DOI: <https://doi.org/10.1016/j.msksp.2018.11.012>.

TEASDALE, G; JENNETT, B. Assessment of coma and impaired consciousness: a practical scale. **The Lancet.** 304 (7872). p. 81-84, 1974.

THAKURIAH, P. V; DIRKS, L; KEITA, Y. M.. Digital infomediaries and civic hacking in emerging urban data initiatives. In: Seeing cities through big data. **Springer, Cham.** p. 189-207, 2017. DOI: https://doi.org/10.1007/978-3-319-40902-3_11.

TOLEDO, D. R. Diferenças sensoriais e motoras entre jovens e idosos: contribuição somatossensorial no controle postural. **Rev Bras Fisioter.** 14(3). p. 267–75. Maio-Junho, 2010. DOI: <https://doi.org/10.1590/S1413-35552010000300004>.

TONEMAN, M; BRAYSHAW, J; LANGE, B; TRIMBOLI, B. Examination of the change in Assessment of Motor and Process Skills performance in patients with acquired brain injury between the hospital and home environment. **Aust Occup Ther J.** 57(4). p. 246-52. Aug, 2010. DOI: <https://doi.org/10.1111/j.1440-1630.2009.00832.x>.

TOPP, R. et al. The effect of bed rest and potential of prehabilitation on patients in the intensive care unit. **AACN Clin Issues.** 13(2). p. 263-76. May, 2002. Disponível em: <https://doi.org/10.1097/00044067-200205000-00011>.

UDDIN, S; KHAN, A; HOSSAIN, M. E; MONI, M.A. Comparing different supervised machine learning algorithms for disease prediction. **BMC Med Inform Decis Mak.** 19(1), 2019. DOI: <https://doi.org/10.1186/s12911-019-1004-8>.

VAN DER AALST, W. Data science in action. In: Process mining. **Springer, Berlin, Heidelberg**, p. 3-23, 2016. DOI: https://doi.org/10.1007/978-3-662-49851-4_1.

VASCONCELOS, R. C; NETO, A. J. M; TELES, L. Proposta de um modelo de mineração de dados educacionais para identificar a colaboração entre estudantes da EAD. **CIET: EnPED**, 2018.

VON HAEHLING, S; STEPNEY, R; ANKER, S. D. Advances in understanding and treating cardiac cachexia: highlights from the 5th Cachexia Conference. **Int J Cardiol.** 144(3). p. 347-9. Oct, 2010. DOI: <https://doi.org/10.1016/j.ijcard.2010.05.042>.

WEI, W; WU, H; MA, H. An AutoEncoder and LSTM-Based Traffic Flow Prediction Method. **Sensors (Basel).** 19(13). p. 2946. Jul, 2019. DOI: <https://dx.doi.org/10.3390/s19132946>.

WINKELMAN, C. Inactivity and inflammation in the critically ill patient. **Crit Care Clin.** 23(1). p. 21-34. Jan, 2007. Disponível em: <https://doi.org/10.1016/j.ccc.2006.11.002> Acesso em: fev. 2021.

YIN, M. et al. Use of artificial neural networks to identify the predictive factors of extracorporeal shock wave therapy treating patients with chronic plantar fasciitis. **Sci Rep.** 9(1). p. 4207. Mar, 2019. DOI: <https://doi.org/10.1038/s41598-019-39026-3>.

ZHANG, S. et. al. Efficient kNN Classification With Different Numbers of Nearest Neighbors. **IEEE Trans Neural Netw Learn Syst.** 29(5), p. 1774-1785. Mar, 2018. DOI: <https://doi.org/10.1109/TNNLS.2017.2673241>.

ZISBERG, A. et al. Hospital-associated functional decline: the role of hospitalization processes beyond individual risk factors. **Am Geriatr Soc.** 63(1). p. 55–62. Jan, 2015. DOI: <https://doi.org/10.1111/jgs.13193>.

8 APÊNDICES

8.1. Apêndice 1 - Termo de Compromisso de Utilização de Dados (TCUD)

Nós, abaixo assinados, pesquisadores envolvidos no projeto de título “Análise preditiva com aprendizado de máquina da recuperação da mobilidade funcional dos pacientes atendidos pelo Serviço de Fisioterapia Hospitalar de um hospital de ensino”, nos comprometemos a manter a confidencialidade sobre os dados pessoais coletados na base de dados do serviço de Fisioterapia do hospital Universitário da UFSC, bem como a privacidade de seus conteúdos, como preconizam os Documentos Internacionais e a Resoluções CNS 466/12 do Ministério da Saúde.

Esclarecemos que os dados a serem coletados se referem aos dados dos pacientes internados em unidade de clínica médica e cirurgia que foram avaliados e atendidos pelo serviço de Fisioterapia, nos meses de Janeiro a Dezembro de 2020.

Declaramos entender a nossa responsabilidade de cuidar da integridade das informações, de garantir a confidencialidade dos dados e a privacidade dos indivíduos que terão suas informações acessadas, bem como de não repassar os dados coletados ou o banco de dados em sua íntegra, ou parte dele, à pessoas não envolvidas na equipe da pesquisa.

Por fim, comprometemo-nos com a guarda, cuidado e utilização das informações apenas para o cumprimento dos objetivos previstos no estudo.

Florianópolis, 12 de Agosto de 2021.



Documento assinado digitalmente
Sayonara de Fatima Faria Barbosa
Data: 15/08/2021 22:56:33-0300
CPF: 723.819.497-04
Verifique as assinaturas em <https://v.ufsc.br>

Dra. Sayonara de Fatima Faria Barbosa - CPF 723.819.497-04

Pesquisador Responsável



Documento assinado digitalmente
Michell Henrique Schwab
Data: 14/08/2021 13:15:47-0300
CPF: 036.936.119-98
Verifique as assinaturas em <https://v.ufsc.br>

Michell Henrique Schwab - CPF 03693611998

Pesquisador Principal

PARECER CONSUBSTANCIADO DO CEP**DADOS DO PROJETO DE PESQUISA**

Título da Pesquisa: Análise preditiva com Aprendizado de Máquina da recuperação da mobilidade funcional dos pacientes atendidos pelo Serviço de Fisioterapia Hospitalar de um hospital de ensino

Pesquisador: Sayonara de Fátima Faria Barbosa

Área Temática:

Versão: 2

CAAE: 48287821.8.0000.0121

Instituição Proponente: Universidade Federal de Santa Catarina

Patrocinador Principal: Financiamento Próprio

DADOS DO PARECER

Número do Parecer: 4.858.415

Apresentação do Projeto:

Trata-se de projeto de dissertação de mestrado de Michell Henrique Schwab, sob orientação de Sayonara F. F. Barbosa e coorientação de Alexandre Gonçalves Silva, do Programa de Pós-Graduação de Mestrado Profissional em Informática em Saúde, da Universidade Federal de Santa Catarina.

As informações que seguem e as elencadas nos campos “Objetivo da pesquisa” e “Avaliação dos riscos e benefícios” foram retiradas do arquivo PB_INFORMACOES_BASICAS_DO_PROJETO_1744037.pdf, de 05/07/2021, preenchido pelos pesquisadores.

Segundo os pesquisadores:

“A perda de mobilidade é um fenômeno comum naqueles pacientes restritos ao leito. A diminuição da atividade física e o repouso contribuem para piora da recuperação do paciente, associado ao aumento dos riscos de doenças associadas. Segundo Cao et al. (2020), um estudo com idosos hospitalizados demonstrou que a baixa mobilidade e o repouso no leito eram comuns e estavam associados a resultados adversos, como declínio na capacidade de realizar atividades da vida diária, morte e institucionalização. No contexto de baixa mobilidade funcional, o serviço de fisioterapia é o responsável pela avaliação e conduta, com o objetivo de prevenir, manter ou

Endereço: Universidade Federal de Santa Catarina, Prédio Reitoria II, R: Desembargador Vitor Lima, nº 222, sala 401

Bairro: Trindade

CEP: 88.040-400

UF: SC

Município: FLORIANOPOLIS

Telefone: (48)3721-6094

E-mail: cep.propesq@contato.ufsc.br

Continuação do Parecer: 4.858.415

melhorar a mobilidade física. Assim essa área do campo da saúde, colabora para minimizar os efeitos deletérios que o tempo prolongado de internação hospitalar provoca nos pacientes, otimizando o tratamento global, repercutindo em um menor tempo de internação, reduzindo a mortalidade e proporcionando uma melhor qualidade de vida após alta hospitalar (CONCEIÇÃO et al., 2014). Quanto ao objeto de pesquisa, pretende-se estudar o nível de recuperação dos pacientes que receberam atendimento fisioterapêutico, durante a internação hospitalar em unidade de clínica médica e cirúrgica do HU/UFSC, sendo para esse fim, utilizado um banco de dados histórico, com dados de janeiro a dezembro de 2020. Por fim, o objetivo é criar um modelo de Aprendizado de Máquina para predição da mobilidade funcional dos pacientes com baixa mobilidade, submetidos à reabilitação fisioterapêutica, durante internação hospitalar em enfermaria”.

Critério de Inclusão:

Serão incluído no estudo o histórico de todos as pessoas atendidas pelo serviço de Fisioterapia, independente de sexo, idade, doença, história médica atual e o estado de saúde prévio, que foram avaliados e acompanhados em enfermaria do hospital universitário.

Critério de Exclusão: Na pesquisa, os dados do numero do registro hospitalar e nomes dos pacientes serão anonimizados. Os atributos que tiverem campos vazios, em número considerável e interfiram na resposta como perda da acurácia, serão excluídos.

Hipótese:

Criação de um modelo de aprendizado de máquina acurado a partir de um banco de dados históricos e um algoritmo de redes neurais artificiais.

Objetivo da Pesquisa:

Segundo os pesquisadores:

Objetivo Primário:

Desenvolver e aplicar uma modelagem de Aprendizado de Máquina para predição do ganho de mobilidade funcional dos pacientes internados em enfermarias, que recebem atendimento fisioterapêutico.

Endereço: Universidade Federal de Santa Catarina, Prédio Reitoria II, R: Desembargador Vitor Lima, nº 222, sala 401
Bairro: Trindade **CEP:** 88.040-400
UF: SC **Município:** FLORIANOPOLIS
Telefone: (48)3721-6094 **E-mail:** cep.propesq@contato.ufsc.br

Continuação do Parecer: 4.858.415

Objetivos Secundários:

Comparar a predição do modelo desenvolvido com o resultado das intervenções fisioterapêuticas no ganho de mobilidade funcional dos pacientes internados em enfermaria do hospital universitário.

Avaliação dos Riscos e Benefícios:

Segundo os pesquisadores:

Riscos:

Quanto ao risco de exposição dos dados dos participantes, pode-se garantir sua segurança, pois os registros são anônimos.

Benefícios:

Os benefícios do estudo poderão ter repercussão positiva no futuro próximo, melhorando a qualidade da assistência na reabilitação fisioterapêutica em enfermaria, estabelecendo as melhores variáveis de avaliação e prognóstico, além de favorecer objetivos e condutas.

Comentários e Considerações sobre a Pesquisa:

Como no estudo será desenvolvido e proposto um modelo preditivo baseado em algoritmos de Machine Learning, é considerado um desenvolvimento tecnológico que por sua definição está focado no desenvolvimento de novos instrumentos. Quanto à natureza do estudo a pesquisa será quantitativa, pois através de análises dos resultados obtidos deve-se obter uma acurácia de ao menos 75%. O local da coleta de dados será o Hospital Universitário Polydoro Ernani de São Thiago da Universidade Federal de Santa Catarina – UFSC. Será utilizada a base de dados - Conjunto de dados do Serviço de Fisioterapia, com 23 atributos e cerca de 1.600 registros.

Na população e amostra do estudo estarão incluídos todos os pacientes internados em unidade de clínica médica e cirurgia que foram avaliados e atendidos pelo serviço de Fisioterapia, dos meses de Janeiro a Dezembro de 2020. As variáveis que serão utilizadas no processo de mineração de dados serão selecionadas durante o desenvolvimento da pesquisa.

Tamanho da Amostra no Brasil: 1.500 (Captação dos registros de avaliação e acompanhamento Fisioterapêutico).

Endereço: Universidade Federal de Santa Catarina, Prédio Reitoria II, R: Desembargador Vitor Lima, nº 222, sala 401

Bairro: Trindade

CEP: 88.040-400

UF: SC

Município: FLORIANOPOLIS

Telefone: (48)3721-6094

E-mail: cep.propesq@contato.ufsc.br

Continuação do Parecer: 4.858.415

Considerações sobre os Termos de apresentação obrigatória:

- 1) Folha de Rosto assinada por Sayonara de Fátima Faria Barbosa, pesquisadora responsável, e Grace Teresinha Marcon Dal Sasso, coordenadora do Programa de Mestrado Profissional em Informática em Saúde da UFSC, em 25/05/2021.
- 2) Cartas de anuência: apresenta declaração assinada por Rosemeri Maurici da Silva, gerente do Hospital Universitário da UFSC (HU-UFSC-EBSERH), em 14/05/2021.
- 3) TCLE: apresenta dispensa de TCLE. Justificativa: “O termo de consentimento livre e esclarecido será dispensado, conforme assinado pelo chefe do serviço de Fisioterapia, e os pesquisadores assinaram o Termo de Compromisso de Utilização de Dados (TCUD)”.
- 4) Apresenta o Termo de Autorização e Compromisso da Instituição coparticipante para uso da Base de dados, assinado por Luiza Martins Faria, Chefe da Unidade de Reabilitação do HU/UFSC/EBSERH, assinado em 15 de março de 2021.
- 5) Cronograma: A coleta de dados iniciará em 26/07/2021 e o término está previsto para 25/08/2021.
- 6) Orçamento: informa despesas de R\$ 7.550,00 com financiamento próprio.

Recomendações:

Vide campo “Conclusões ou Pendências e Lista de Inadequações”.

Conclusões ou Pendências e Lista de Inadequações:

Conclusão: Os pesquisadores resolveram as pendências listadas no parecer número 4.813.011 e o projeto está aprovado.

Lembramos aos pesquisadores que, no cumprimento da Resolução 466/12, o CEPESH/UFSC deverá receber, por meio de notificação, os relatórios parciais sobre o andamento da pesquisa e o relatório completo ao final do estudo. Eventuais modificações ou emendas ao protocolo devem ser apresentadas de forma clara e sucinta, identificando a parte do protocolo a ser modificada e as suas justificativas.

Endereço: Universidade Federal de Santa Catarina, Prédio Reitoria II, R: Desembargador Vitor Lima, nº 222, sala 401
Bairro: Trindade **CEP:** 88.040-400
UF: SC **Município:** FLORIANOPOLIS
Telefone: (48)3721-6094 **E-mail:** cep.propesq@contato.ufsc.br

Continuação do Parecer: 4.858.415

Considerações Finais a critério do CEP:

Este parecer foi elaborado baseado nos documentos abaixo relacionados:

Tipo Documento	Arquivo	Postagem	Autor	Situação
Informações Básicas do Projeto	PB_INFORMAÇÕES_BÁSICAS_DO_PROJETO_1744037.pdf	05/07/2021 14:25:22		Aceito
Projeto Detalhado / Brochura Investigador	Projeto_CEPSH_ajustes.pdf	05/07/2021 14:18:00	MICHELL HENRIQUE SCHWAB	Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	Termo_de_Responsabilidade_Servico_de_Fisioterapia.pdf	05/07/2021 14:17:21	MICHELL HENRIQUE SCHWAB	Aceito
Projeto Detalhado / Brochura Investigador	Projeto_de_Pesquisa.pdf	25/05/2021 15:39:50	MICHELL HENRIQUE SCHWAB	Aceito
Declaração de Instituição e Infraestrutura	Carta_de_Anuencia.pdf	25/05/2021 15:37:26	MICHELL HENRIQUE SCHWAB	Aceito
Folha de Rosto	Folha_de_Rosto.pdf	25/05/2021 15:32:45	MICHELL HENRIQUE	Aceito

Situação do Parecer:

Aprovado

Necessita Apreciação da CONEP:

Não

FLORIANOPOLIS, 20 de Julho de 2021

Assinado por:
Nelson Canzian da Silva
(Coordenador(a))

Endereço: Universidade Federal de Santa Catarina, Prédio Reitoria II, R: Desembargador Vitor Lima, nº 222, sala 401
Bairro: Trindade **CEP:** 88.040-400
UF: SC **Município:** FLORIANOPOLIS
Telefone: (48)3721-6094 **E-mail:** cep.propesq@contato.ufsc.br



HOSPITAL UNIVERSITÁRIO DA UNIVERSIDADE FEDERAL DE SANTA CATARINA
Rua Profa. Maria Flora Pausewang, s/nº - Bairro Trindade
Florianópolis-SC, CEP 88036-800
- <http://hu-ufsc.ebserh.gov.br>

Carta - SEI nº 10/2021/SGPIT/GEP/HU-UFSC-EBSEH

Florianópolis, *data da assinatura eletrônica.*

CARTA DE ANUÊNCIA

1. Informo para os devidos fins e efeitos legais, objetivando atender as exigências para a obtenção de parecer do Comitê de Ética em Pesquisa com Seres Humanos, e como representante legal da Instituição, estar ciente do projeto de pesquisa: **“ANÁLISE PREDITIVA COM APRENDIZADO DE MÁQUINA DA RECUPERAÇÃO DA MOBILIDADE FUNCIONAL DOS PACIENTES ATENDIDOS PELO SERVIÇO DE FISIOTERAPIA HOSPITALAR DE UM HOSPITAL DE ENSINO”**, sob a responsabilidade do Pesquisador Principal **MICHELL HENRIQUE SCHWAB**.
2. Declaro ainda conhecer e cumprir as orientações e determinações fixadas na Resolução nº 466, de 12 de dezembro de 2012, do Conselho Nacional de Saúde e demais legislações complementares.
3. No caso do não cumprimento, por parte do pesquisador, das determinações éticas e legais, a Gerência de Ensino e Pesquisa tem a liberdade de retirar a anuência a qualquer momento da pesquisa sem penalização alguma.
4. Considerando que esta instituição tem condição para o desenvolvimento deste projeto, autorizo a sua execução nos termos propostos mediante a plena aprovação do CEP competente.

(assinada eletronicamente)

Gerente de Ensino e Pesquisa



Documento assinado eletronicamente por **Rosemeri Maurici da Silva, Gerente**, em 14/05/2021, às 13:16, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://sei.ebserh.gov.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **13594155** e o código CRC **5C6CEBBC**.

Referência: Processo nº 23820.003787/2021-46 SEI nº 13594155