

UNIVERSIDADE FEDERAL DE MINAS GERAIS
Instituto de Ciências Biológicas
Programa de Pós-graduação em Neurociências

Arthur Afonso Silva-Sousa

**ESTRATÉGIAS DE *MACHINE LEARNING* PARA PREDIÇÃO DE MORTALIDADE
EM TRAUMATISMO CRANIOENCEFÁLICO:
uma revisão sistemática da literatura**

Belo Horizonte

2023

Arthur Afonso Silva-Sousa

**ESTRATÉGIAS DE *MACHINE LEARNING* PARA PREDIÇÃO DE MORTALIDADE
EM TRAUMATISMO CRANIOENCEFÁLICO:
uma revisão sistemática da literatura**

Dissertação

Dissertação apresentada ao Programa de Pós-graduação em Neurociências da Universidade Federal de Minas Gerais, como requisito parcial à obtenção do título de Mestre em Neurociências.

Orientadora: Aline Silva de Miranda

Coorientador: Rafael Alves Bonfim de Queiroz

Belo Horizonte

2023

043

Silva-Sousa, Arthur Afonso.

Estratégias de Machine Learning para predição de mortalidade em Traumatismo Cranioencefálico: uma revisão sistemática da literatura [manuscrito] / Arthur Afonso Silva-Sousa. – 2023.

37 f.: il. ; 29,5 cm.

Orientadora: Aline Silva de Miranda. Coorientador: Rafael Alves Bonfim de Queiroz.

Dissertação (mestrado) – Universidade Federal de Minas Gerais, Instituto de Ciências Biológicas. Programa de Pós-graduação em Neurociências.

1. Neurociências. 2. Traumatismos Craniocerebrais. 3. Mortalidade. 4. Aprendizado de Máquina. 5. Revisão Sistemática. I. Miranda, Aline Silva de. II. Queiroz, Rafael Alves Bonfim de. III. Universidade Federal de Minas Gerais. Instituto de Ciências Biológicas. IV. Título.

CDU: 612.8



UNIVERSIDADE FEDERAL DE MINAS GERAIS
INSTITUTO DE CIÊNCIAS BIOLÓGICAS
PROGRAMA DE PÓS-GRADUAÇÃO EM NEUROCIÊNCIAS

ATA DE DEFESA DE DISSERTAÇÃO DO ALUNO

ARTHUR AFONSO SILVA E SOUSA

Realizou-se, no dia 16 de maio de 2023, às 14:00 horas, sala virtual google meet., da Universidade Federal de Minas Gerais, a 259ª defesa de dissertação, intitulada *Estratégias de machine learning para predição de mortalidade em traumatismo cranioencefálico: revisão sistemática da literatura.*, apresentada por ARTHUR AFONSO SILVA E SOUSA, número de registro 2021661088, graduado no curso de PSICOLOGIA, como requisito parcial para a obtenção do grau de Mestre em NEUROCIÊNCIAS, à seguinte Comissão Examinadora: Profa. Aline Silva de Miranda - Orientadora (UFMG), Prof. Rafael Alves Bonfim de Queiroz (UFOP), Prof. Victor Rodrigues Santos (UFMG), Profa. Fernanda Carolina Camargo (UFTM).

A Comissão considerou a dissertação: Aprovada

Finalizados os trabalhos, lavrei a presente ata que, lida e aprovada, vai assinada por mim e pelos membros da Comissão.
Belo Horizonte, 16 de maio de 2023.

Carlos Magno Machado Dias - Secretário

Assinatura dos membros da banca examinadora:

Profa. Aline Silva de Miranda (Doutora)

Prof. Rafael Alves Bonfim de Queiroz (Doutor)

Prof. Victor Rodrigues Santos (Doutor)

Profa. Fernanda Carolina Camargo (Doutora)



Documento assinado eletronicamente por **Victor Rodrigues Santos, Professor do Magistério Superior**, em 16/05/2023, às 16:55, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Rafael Alves Bonfim de Queiroz, Usuário Externo**, em 16/05/2023, às 17:21, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Aline Silva de Miranda, Servidor(a)**, em 16/05/2023, às 17:40, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Fernanda Carolina Camargo, Usuária Externa**, em 23/05/2023, às 17:03, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufmg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **2300128** e o código CRC **BE915204**.



UNIVERSIDADE FEDERAL DE MINAS GERAIS
INSTITUTO DE CIÊNCIAS BIOLÓGICAS
PROGRAMA DE PÓS-GRADUAÇÃO EM NEUROCIÊNCIAS

FOLHA DE APROVAÇÃO

Estratégias de machine learning para predição de mortalidade em traumatismo craniocéfálico: revisão sistemática da literatura.

ARTHUR AFONSO SILVA E SOUSA

Dissertação submetida à Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em NEUROCIÊNCIAS, como requisito para obtenção do grau de Mestre em NEUROCIÊNCIAS, área de concentração NEUROCIÊNCIAS CLÍNICAS.

Aprovada em 16 de maio de 2023, pela banca constituída pelos membros:

Profa. Fernanda Carolina Camargo
UFTM

Prof. Rafael Alves Bonfim de Queiroz
UFOP

Prof. Victor Rodrigues Santos
UFMG

Profa. Aline Silva de Miranda - Orientadora
UFMG

Belo Horizonte, 16 de maio de 2023.



Documento assinado eletronicamente por **Victor Rodrigues Santos, Professor do Magistério Superior**, em 16/05/2023, às 16:55, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Rafael Alves Bonfim de Queiroz, Usuário Externo**, em 16/05/2023, às 17:19, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Aline Silva de Miranda, Servidor(a)**, em 16/05/2023, às 17:40, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Fernanda Carolina Camargo, Usuária Externa**, em 23/05/2023, às 17:04, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufmg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **2300164** e o código CRC **788B2ED8**.

*Dedico este trabalho às pessoas que
contribuem significativamente para que minha
vida e meus esforços tenham sentido: Maria
Luiza, Kayla e Zaki.*

Agradecimentos

“Tudo, tudo, tudo que nós tem é nós” – Principia, Emicida

Clarice escreveu que quem caminha sozinho vai mais rápido, mas quem caminha junto vai mais longe. Eu não me atreveria a contestá-la, exceto pela ousadia que me preenche o peito ao terminar esta jornada que nasce em forma de texto escrito. A caminhada até aqui me mostrou que sozinho eu não só não vou mais rápido, como também não vou a lugar algum. Especialmente falando de uma jornada árdua que envolve a pós-graduação.

Apesar de perceber a pesquisa como um lugar solitário, afinal é apenas você e seu objeto de estudo, reconheço que uma pesquisa é feita de muitas mãos. Sejam elas as que te orientam, que escrevem contigo, sejam elas as mãos que te amparam e dão suporte na caminhada. Dessa forma, incorrendo o risco de a memória falhar e eu esquecer-me de citar alguém, adianto-me pedindo desculpas. Isto definitivamente não significa desprezo pela experiência compartilhada, outrossim, apenas um deslize habitual de um humano. Portanto, agradeço:

À Maria Luiza, Kayla e Zaki, por me darem sentido à vida. Por me realizarem como ser humano e me fazerem compreender que uma vida plena e feliz é uma vida em que vocês habitam nela.

Aos meus avós Eudes (*in memoriam*) e Maria, por serem a tradução perfeita de amor, cuidado e suporte. Nada do que sou seria possível sem quem vocês são para mim.

À minha mãe, por me apoiar incondicionalmente. Por nunca ter me perdido de vista e por ter se feito presente em momentos cruciais, especialmente nestes dois últimos anos.

À minha irmã Natália, por ser tudo que eu preciso. Sempre. Sou infinitamente grato por termos o amor um do outro. Obrigado por estar sempre na retaguarda.

Às minhas tias Edi e Coca, por serem fonte de inspiração e por, ativamente, me lembrarem que tenho um lugar para voltar.

Ao tio Conrado, tia Ezi, tia Eleusa, pelo entusiasmo que sempre depositaram em minhas conquistas.

Aos meus primos Thiago, Geovanna, Maria Laura e Duda, por me lembrarem o valor da família e do quanto a presença de vocês é indispensável para eu entender o lugar que eu pertenço no mundo.

À Isabela Borches Dias Carvalho, por nunca ter deixado de acreditar em mim, mas, sobretudo, de me incentivar a viver a vida que quero. Obrigado por ser um espaço de cuidado, de refúgio e de entretenimento nas atribulações que a vida me impôs nos últimos tempos.

À Júlia Heitor Bevilacqua, por cultivar o amor e mostrar o poder dos encontros sutis e delicados que a vida nos proporciona. Especialmente, agradeço por todo amparo nos tempos finais da dissertação. Obrigado por ter dividido sua experiência e por ser uma das melhores representações da palavra *colo*.

À Ana Carolina Canassa Marques, por absolutamente tudo. Por ter sido abrigo nos momentos delicados e por ser fonte inesgotável de encorajamento. Obrigado por cada chá, lanches e filmes que me permitiram me conectar com outras versões de mim, tão importantes quanto a de pesquisador. Obrigado pelo apoio incondicional.

À Nadyara Oliveira, por me ajudar a entender que eu estava cansado e que pessoas cansadas não desistem, elas descansam. Obrigado por me ajudar a dar nome para as coisas e a geri-las.

À Talita Grizólio, por, provavelmente, ser uma das maiores entusiastas das minhas conquistas. Sua disposição em se alegrar comigo sempre foi e será um combustível para minha caminhada.

À Claudiane Aparecida Guimarães e Sofia Nobre Novais, pelo acolhimento e compreensão das minhas necessidades ao longo da realização desta pesquisa e pelas palavras

de apoio ao longo do percurso. À Mariana da Silva Lauriano, por ser uma amiga incrível e parceira nos momentos de grandes crises. Obrigado por todo acolhimento e torcida sincera!

Ao Guilherme Faquim Simão, Fabiana da Silva Almeida e Matheus Fernando Felix Ribeiro, pelas conversas que me ajudaram a sustentar a angústia do fim. Gui, obrigado por me dar contorno às experiências. Fabi, obrigado por construir comigo um plano de gestão de crise, sem o qual seria impossível terminar a pesquisa com saúde e afimco.

À Thainá Cristina Pereira, por sempre ser presença, mesmo nos momentos que a vida adulta nos convidou a estar ausentes. Agradeço pela disponibilidade de sempre e pela correção do *abstract*.

À Luana Mollinar, Lacilaura Lamounier, Ana Luiza Rosa Lucas e Vitória Oliveira, pelas palavras de incentivo e entusiasmo, especialmente nos momentos que eu não sabia de onde tirar força para dar conta.

À Maria Gabryella Ribeiro, Kellen Raíssa dos Santos, Raquel Lima Dornfeld, Anelise Cobo Prata, Nathália Gabriele Melo, pelo companheirismo de sempre e pelo lembrete de que tenho morada em outros corações, amigas para todas as situações.

À Raquel Nunes, por ser um dos meus lugares seguros.

Ao Pedro Henrique Zani Jovanelli, por ter sido um “guru” em minha vida, dando contorno e me ensinando a ter sobrevida quando o caos se instaurou ao longo do percurso acadêmico.

À Maria, ao Black e à Vitória, que me ensinam que o amor está nas coisas ordinárias da vida.

Agradeço profundamente à minha orientadora, doutora Aline Silva de Almeida, pela generosidade. Agradeço por ter aceitado uma conversa inicial e pela disponibilidade em negociar nossos interesses acadêmicos. Agradeço a gentileza depositada em nossas conversas e orientações. Sem dúvidas, você é uma grande inspiração para mim.

Ao meu coorientador, doutor Rafael Alves Bonfim de Queiroz, pela delicadeza, atenção e cuidado com meu trabalho. Agradeço por ter sido um coorientador presente e disponível. Obrigado pelas contribuições valiosas sobre meu trabalho e por me guiar no caminho do entendimento sobre *machine learning*.

Às minhas queridas professoras e amigas Amora de Faria e Rosimár Alves Querino, por sempre terem apostado em mim e me encorajarem a progredir acadêmica e pessoalmente. Vocês indispensáveis em minha jornada. Agradeço à Amora, por ser minha mentora de vida. Obrigado por cada porta aberta, por cada café e conversas que me edificaram. Agradeço à Rosimár, por ser um ponto de luz no mundo. Por iluminar minha jornada e não me perder de vista.

À doutora Fernanda Carolina Camargo, pelo apoio incondicional em todas as minhas fases acadêmicas. Sou muito grato por você acreditar e desenvolver meu potencial, me incluindo em seus projetos e ampliando meus horizontes. Eu não seria metade do pesquisador que sou se não fosse pelo seu encorajamento – anterior à graduação até os dias atuais. Mais especificamente nesta pesquisa, agradeço pelas dicas e por me mostrar os caminhos viáveis para consolidação da pesquisa no sistema de saúde.

Ao Leopoldo Mandic Ferreira Furtado, por ter sido um excelente parceiro na construção desta pesquisa. Obrigado pelas dicas, pela disponibilidade e pela ajuda fundamental na coleta de dados.

À professora doutora Zilda Pereira da Silva, por ter me recebido como aluno especial em sua matéria de Informações de saúde: métodos de análise. Esta disciplina foi fundamental para a construção desta e de futuras pesquisas.

Agradeço às pessoas que, direta ou indiretamente, me auxiliaram no ingresso no mestrado: aos professores doutora Paula Luciana Scalzo, doutor Victor Rodrigues Santos e mestre Julián Tadeo Felipe Veja que, por meio de seu curso sobre Neurociências, me

viabilizaram o ingresso no programa de pós-graduação; à Clarice Santana e Carina Barbosa por terem montado o grupo de estudos para a seleção e por terem se feito presentes nestes dois últimos anos; à doutora Aline da Silva Almeida e à mestre Isaura Beatriz Borges Silva, pela ajuda na construção do anteprojeto, que me viabilizou aprovação no mestrado; à tia Coca, Vó, Natália e Ana, por estarem na base dessa conquista inicial, meus mais sinceros obrigado.

Agradeço aos professores da pós-graduação. Em especial, à professora Paula Scalzo, da UFMG, e Zilda Pereira, da USP-SP. O percurso da pós-graduação é um grande desafio, mas quando se esbarra com pessoas tão disponíveis e interessadas em transformar o mundo pela educação, fica mais fácil de suportar o desafio.

Agradeço ainda aos governos do PT, que, por meio de suas ações afirmativas e fomento à educação e desenvolvimento tecnológico no Brasil, viabilizaram meus estudos e permitiram a minha obtenção dos títulos acadêmicos.

À CAPES, pelo apoio financeiro para a realização desta pesquisa.

Por fim, que é o início, agradeço a Exu, por abrir meus caminhos e aos Orixás por mantê-lo aberto e protegido.

"Que a importância de uma coisa não se mede com fita métrica nem com balanças nem com barômetros etc. Que a importância de uma coisa há que ser medida pelo encantamento que a coisa produza em nós."

Manoel de Barros

Resumo

O traumatismo cranioencefálico (TCE) tem sido reconhecido como uma das principais causas de morbimortalidade em todo o mundo, sendo considerado uma epidemia silenciosa. Considera-se uma variedade de causas de TCE, tais como quedas, acidentes automobilísticos, assaltos e agressões. Apesar de intensos investimentos, ainda não possui um tratamento aprovado para mitigar os danos provocados por lesões secundárias de TCE, sendo a prevenção o melhor tratamento atualmente. Com o avanço tecnológico, técnicas de *machine learning* (ML) têm sido utilizadas na área da saúde para predições de desfecho e auxílio em tomadas de decisões terapêuticas, por exemplo, risco de mortalidade em vítimas de TCE. Contudo, na mesma medida em que há significativo desenvolvimento de técnicas de ML para este fim, não há consenso sobre quais estratégias apresentam melhor desempenho para prever a mortalidade. A partir do exposto, o objetivo do presente trabalho foi realizar uma revisão sistemática acerca das produções científicas que utilizam técnicas de *machine learning* para predição de mortalidade decorrentes de TCE. Para este fim, a pergunta de pesquisa foi formulada a partir da estratégia PICO (Pessoa, Intervenção, Comparação, *Outcome*), tendo como critérios de inclusão artigos científicos publicados em revistas indexadas na Biblioteca Virtual em Saúde (BVS) e na *National Library of Medicine* (PubMed), escritos em inglês, português e espanhol, que tivessem mortalidade como um dos desfechos do estudo. Foram excluídos estudos com modelos animais, com foco em análises moleculares e artigos que não foram encontrados para leitura na íntegra. A coleta de dados ocorreu em abril de 2022, por dois pesquisadores independentes e, para as análises, foi construído um protocolo específico para este estudo. Dos 1181 estudos encontrados, 26 atenderam aos critérios de elegibilidade e foram incluídos para análise nesta revisão. O maior número de publicações se deu entre os países dos Tigres Asiáticos (n=7, 26,9%), com estudos retrospectivos (n=16, 61,5%) e amostra de adultos (n=19, 73,1%). A média geral de idade foi de 47,8 anos, apresentando

predominância do sexo masculino entre as vítimas de TCE e as principais causas foram acidente de trânsito, queda e objeto atingindo a cabeça. As principais variáveis que predisseram mortalidade foram idade e resposta pupilar (n=10, 9,4%) e baixos escores na escala de coma de Glasgow (n=9, 8,5%). Foram encontrados 59 algoritmos de *machine learning*, sendo os que apresentaram melhor desempenho *Artificial Neural Networks*, *Support Vector Machine*, e *Random Forest*, especialmente se comparados com o algoritmo tradicional de regressão logística. A partir dos resultados obtidos, pode-se concluir, preliminarmente, que as estratégias de ML são uma ferramenta útil e eficaz para predição de mortalidade em TCE, favorecendo a tomada de decisão clínica. Como perspectiva deste estudo, propõe-se a avaliação de risco de viés, atualização da busca, incluindo o descritor inteligência artificial e realização de meta-análise, segundo permitam os dados.

Palavras-chave: Traumatismo cranioencefálico. Mortalidade. *Machine learning*. Revisão sistemática.

Abstract

Traumatic brain injury (TBI) has been recognized as one of the main causes of morbidity and mortality worldwide, being considered a silent epidemic. A variety of causes of TBI are considered, such as falls, car accidents, robberies and assaults. Despite intense investments, there is not still an approved treatment to mitigate the damage caused by secondary TBI injuries, and prevention is currently the best treatment. With technological advances, machine learning (ML) techniques have been used in the health field to predict outcomes and aid in therapeutic decision-making, for example, mortality risk in TBI victims. However, to the same extent that there is a significant development of ML techniques for this purpose, there is no consensus on which strategies have the best performance in predicting mortality. Based on the above, the objective of this study was to carry out a systematic review of scientific productions that use machine learning techniques to predict mortality due to TBI. To this end, the research question was formulated from the PICO strategy (Person, Intervention, Comparison, Outcome), having as inclusion criteria scientific articles published in journals indexed in the Virtual Health Library (BVS) and the National Library of Medicine (PubMed), written in English, Portuguese and Spanish, that had mortality as one of the study outcomes. Studies with animal models, focusing on molecular analyzes and articles that were not found for reading in full were excluded. Data collection took place in April 2022, by two independent researchers and, for the analyses, a specific protocol was constructed. Of the 1181 studies found, 26 met the eligibility criteria and were included for analysis in this review. The largest number of publications occurred among the Four Asian Tiger countries (n=7, 26.9%), with retrospective studies (n=16, 61.5%) and adult sample (n=19, 73.1%). The overall mean age was of 47.8, with a predominance of males among TBI victims and the main causes were traffic accidents, falls and objects hitting the head. The main variables that predicted mortality were age and pupillary response (n=10, 9.4%) and low scores on the

Glasgow Coma Scale (n=9, 8.5%). Fifty-nine machine learning algorithms were found, with the best performance being Artificial Neural Networks, Support Vector Machine, and Random Forest, especially when compared to the traditional logistic regression algorithm. Based on the results obtained, it can be preliminarily concluded that LM strategies are a useful and effective tool for predicting mortality in TBI, favoring clinical decision-making. As a perspective of this study, it is proposed to assess the risk of bias, update the search, including the artificial intelligence descriptor and perform a meta-analysis, as the data allow.

Keywords: Traumatic brain injury. Mortality. Systematic Review. Machine Learning.

Lista de Abreviaturas e Siglas

1-NN – 1-Nearest-Neighbor

3-NN – 3-Nearest-Neighbors

AD – Análise discriminante

ANN – Artificial Neural Networks

BaT – Bagged trees

BM – Bayesian Methods

BN – Bayesian network

Boosting – Boosting

BT – Boosted trees

BVS – Portal Regional da Biblioteca Virtual em Saúde

CART – Classification and regression trees

CatBoost – CatBoost

CCP – Compound Covariate Predictor

CG-SVM – Coarse Gaussian Support Vector Machine

C-KNN – Cosine K-Nearest Neighbor

Co-KNN – Coarse K-Nearest Neighbor

CPMDeepMN – Rede neural feedforward ponderada por classe com uma camada de saída multinomial

CPMDeepOR – Rede neural feedforward ponderada por classe com uma camada de saída ordinal

CPMMNLR – Regressão logística multinomial

CPMPOLR – Regressão logística

CRASH model – CRASH model

CRF – Classification Random Forest

C-SVM – Cubic Support Vector Machine

CT – Complex tree

Cu-KNN – Cubic K-Nearest Neighbor

DA – Discriminant Analysis

DL – Linear discriminant

DLD – Diagonal Linear Discriminant

DNN – Deep Neural Networks

DT – Decisions Tree

EN – Elastic Net

ET – Extra trees

FG-SVM – Fine Gaussian Support Vector Machine

F-KNN – Fine K-Nearest Neighbor

GBM – Gradient boosting machine

GBoosting – Gradient Boosting

GLM – Generalized Linear Model

GNB – Gaussian naive Bayes

K-NN – K-Nearest Neighbor

LightGBM – Light Gradient boosting machine

LRnet – Local Relation Network

L-SVM – Linear Support Vector Machine

MARS – Multivariate Adaptive Regression Splines

MG-SVM – Medium Gaussian Support Vector Machine

M-KNN – Medium K-Nearest Neighbor

ML – Machine Learning

MLP – Multi layer perceptron

MNB – Multimodal naive Bayes

MT – Medium tree

NB – Naïve Bayes

NC – Nearest-Centroid

NN – Neural nets

PLS – Partial Least Squares

PRISMA – Principais Itens para Relatar Revisões sistemáticas e Meta-análises

PubMed – National Library of Medicine

QD – Quadratic discriminant

Q-SVM – Quadratic Support Vector Machine

QUÓRUM – Qualidade dos relatos de meta-análise

REP Tree – Reduce Error pruning tree

RF – Random Forest

RL – Regressão Logística

RLa – Regressão Lasso

Rli – Regressão linear

RR – Regressão Ridge

RT – Random tree

RUSBT – RUSBoosted trees

SD – Subspace discriminant

S-KNN – Subspace K-Nearest Neighbor

SNN – Spiking neural networks

SRF – Survival Random Forest

ST – Simple tree

SVM – Support Vector Machine

TCE – Traumatismo Cranioencefálico

W-KNN – Weighted K-Nearest Neighbor

XGBoost – Extreme Gradient Boosting

Sumário

Introdução	22
Resumo do Método.....	24
Principais Resultados.....	25
Seleção do estudo	25
Características dos estudos.....	26
Desfechos, amostra e técnicas de <i>Machine Learning</i>	28
Considerações finais	30
Perspectiva	31
Referências.....	32
Apêndice	36
Apêndice A – Protocolo de diretrizes para o estudo	36
Apêndice B – Protocolo de extração dos dados	37

Introdução

Trauma é a principal causa de morte em indivíduos entre 1 e 45 anos, sendo o traumatismo cranioencefálico (TCE) responsável pela maioria destas mortes (Vella et al., 2017). Ele é resultado de mecanismos contundentes ou penetrantes na cabeça ou aceleração por forças de aceleração-desaceleração (Thurman et al., 1995; Vella et al., 2017), causando danos anatômicos como fraturas ou lacerações do couro cabeludo ou comprometam o funcionamento de estruturas do crânio ou encéfalo (Magalhães et al., 2017; Magalhães et al., 2022; Silva et al., 2019). O TCE é a principal causa de morbimortalidade em politraumatizados (Magalhães et al., 2022; Silva, 2018).

Estima-se que mais de um milhão de brasileiros vivam com sequelas permanentes como consequência de TCE (Magalhães et al., 2017), envolvendo altos gastos anuais com serviços hospitalares, bem como seguridade social e consequências econômicas para as famílias e cuidadores desses pacientes (Silva, 2018). Considerando a alta incidência, o alto potencial incapacitante e o impacto em pessoas economicamente ativas, o TCE é considerado um grave problema de saúde pública ao redor do mundo (Almeida et al., 2016; Carteri & Silva, 2021; Silva, 2018), sendo considerado uma “epidemia silenciosa”.

Nas últimas décadas, importantes avanços no tratamento de TCE têm sido realizados. Contudo, os tratamentos disponíveis são direcionados para suporte à vida, em geral, focados nas lesões primárias. As estratégias variam conforme a gravidade e os recursos, sendo, em geral, utilizadas técnicas que mantenham o fluxo sanguíneo cerebral adequado, evitando hipóxia (Vella et al., 2017). Isto pode ser feito por meio da elevação da cabeça, hiperventilação (Galgano et al., 2017), drenagem de líquido cefalorraquidiano (Vella et al., 2017), coma induzido, terapia hiper osmolar e craniotomia descompressiva (Galgano et al., 2017; Vella et al., 2017). Em alguns casos, pode ser indicado intubação e ventilação mecânica, como formas de proteger as vias aéreas (Capizzi et al., 2020). A terapia de

resfriamento tem sido uma possibilidade para tratamento de estresse oxidativo, tido como lesão secundária. Entretanto, sua eficácia na prevenção das sequelas neuropsiquiátricas resultantes do TCE permanece pouco elucidada (Galgano et al., 2017).

Além disso, as lesões traumáticas no Brasil constituem a maior causa de morte entre 10 e 29 anos (Silva et al. 2018) e o TCE ocupa a terceira causa de morte, configurando-se como um problema para os gestores em saúde (Nascimento et al., 2020). Em um estudo local, Areas et al. (2019) encontrou uma proporção de 9,5 casos para cada 100.000 habitantes, com taxa de mortalidade de 5,43/100.000 habitantes por ano.

Ante o exposto, diferentes estudos buscaram avaliar a relação e, mais recentemente, a predição de algumas condições clínicas resultantes de TCE (Irimia et al., 2020; Rostowsky & Irimia, 2021) ou mesmo de sua gravidade (Minaee et al., 2019). Usualmente, o desfecho clínico é avaliado por meio de métodos estatísticos, mas, atualmente, técnicas de *machine learning* (ML) têm sido utilizados para este fim (Tunthanathip & Oearsakul, 2021). ML consiste em algoritmos capazes de generalizar regras e padrões, a partir de um conjunto de dados de entrada pré-estabelecidos (Mateos-Pérez et al., 2018).

Este conhecimento é utilizado para gerar previsões ou classificações em dados não vistos antes (Mateos-Pérez et al., 2018). As neurociências têm sido bastante beneficiadas pela técnica de ML, construindo classificadores ou preditores de algumas doenças como neuro-oncologia (Papp et al., 2018; Valdebenito & Medina, 2019), acidente vascular encefálico (Heo et al., 2019), complicações pós-operatórias (Tunthanathip et al., 2019) e TCE (Amorim et al., 2020).

A abordagem por ML, especialmente ML supervisionada, também tem sido utilizada para predizer desfechos clínicos de TCE (Tunthanathip & Oearsakul, 2021). Entre as possíveis técnicas utilizadas, é possível dividi-las em quatro grandes grupos: aprendizado

supervisionado, aprendizado não supervisionado, aprendizagem semi-supervisionada e aprendizado por reforço (Choi et al., 2020).

O TCE é um dos dez temas mais frequentemente estudados utilizando estratégias de ML (Sakai & Yamada, 2018), promovendo avanço e utilidade na área das neurociências (Tunthanathip & Oearsakul, 2021). Apesar disso, ainda não há uma convenção de qual técnica é mais efetiva para casos de TCE, como demonstra o apanhado realizado por (Tunthanathip & Oearsakul, 2021). Dessa forma, torna-se fundamental investigar quais técnicas de *machine learning* têm sido mais empregadas com sucesso para predição de mortalidade de TCE. Diante do exposto, o objetivo do presente estudo foi agrupar e sistematizar as produções científicas que utilizam técnicas de *machine learning* para predição de mortalidade decorrentes do TCE.

Resumo do Método

Trata-se de um estudo teórico, do tipo revisão sistemática. Este tipo de estudo visa identificar, avaliar e sumarizar as descobertas de todos os estudos relevantes, tornando mais acessível as evidências para as pessoas tomarem decisões embasadas. Esta revisão seguiu todas as diretrizes do grupo Cochrane para revisão sistemática e meta-análises (Higgins & Thomas, 2022). A partir dessas diretrizes, foi construído um protocolo de diretrizes do estudo (Apêndice A).

A formulação da pergunta de pesquisa foi estabelecida a partir da estratégia PICO (Santos, Pimenta, & Nobre, 2007). PICO trata-se de um acrônimo para População, Intervenção, Comparação e *Outcome* (Desfecho). À vista disso, a pergunta formulada foi “Quais são as estratégias de *machine learning* utilizadas para predição de mortalidade decorrente de Traumatismo Cranioencefálico?”, sendo População: vítimas de TCE, Intervenção: o uso de *machine learning*, Comparação: as diferentes estratégias usadas pelos trabalhos e Desfecho: a predição de mortalidade.

A coleta de dados foi realizada nas bases de dados Portal Regional da Biblioteca Virtual em Saúde (BVS) e *National Library of Medicine* (PubMed). Posteriormente, foi utilizada a recomendação Principais Itens para Relatar Revisões sistemáticas e Meta-análises (PRISMA). Durante a coleta, dois pesquisadores independentes fizeram as buscas em abril de 2022.

Os descritores e as palavras-chave adotados para a busca foram “*traumatic brain injury*” e “*head trauma*”, sendo combinados com os descritores “*machine learning*” e “*deep learning*”. Após a busca, foram excluídos os artigos duplicados e os pesquisadores procederam avaliando os títulos e resumos, de acordo com os critérios de elegibilidade. Posteriormente os artigos foram lidos na íntegra e os mesmos critérios de inclusão/exclusão foram aplicados, construindo, por fim, o *corpus* de artigos que foram incluídos nesta revisão.

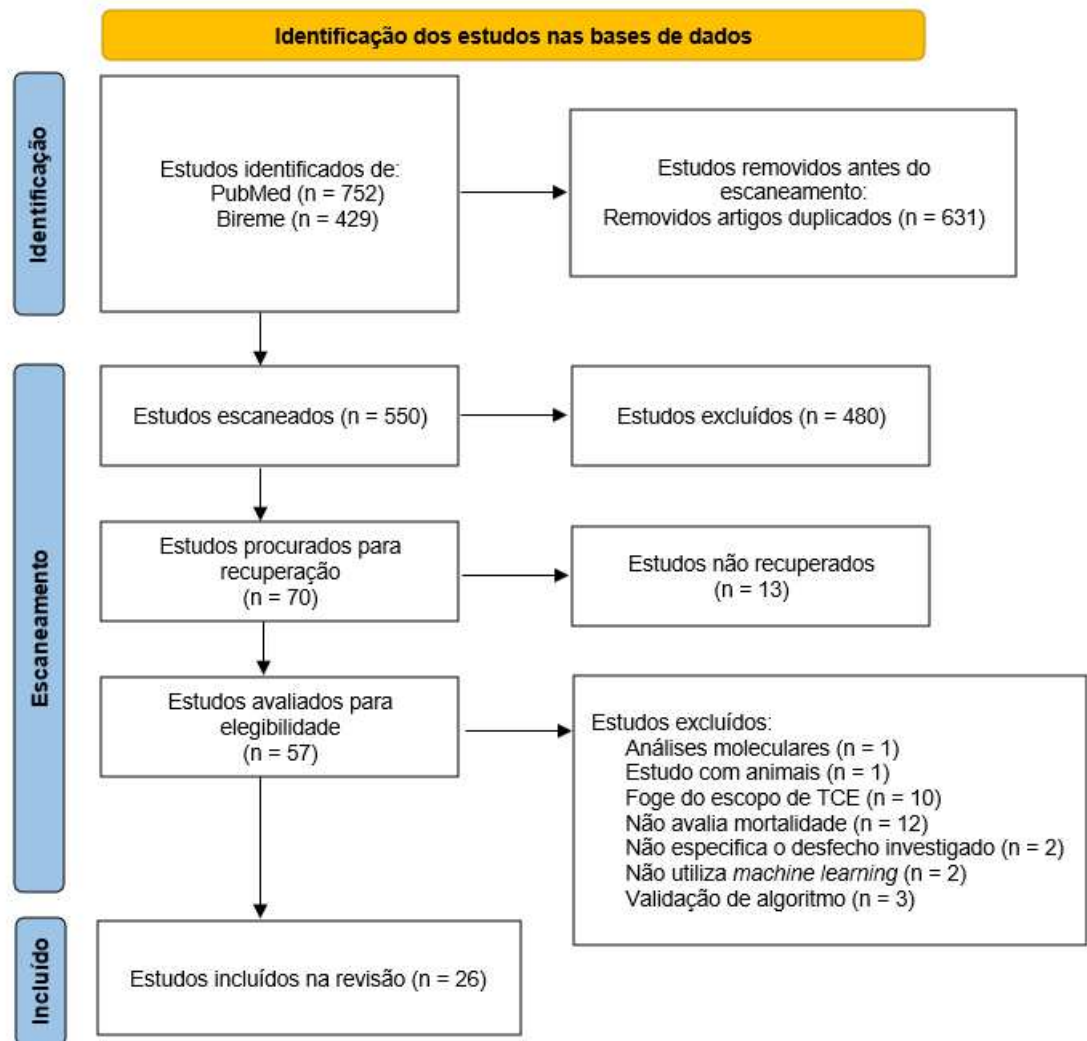
A extração dos dados se deu a partir de protocolo construído especificamente para este estudo (apêndice B), a fim de obter informações acerca da caracterização da amostra, bem como os mecanismos de trauma e técnicas de *machine learning* empregadas. Uma vez que se trata de um estudo teórico, bibliográfico e com dados disponíveis publicamente, o projeto não foi submetido à plataforma Brasil para apreciação do Comitê de Ética em Pesquisa.

Principais Resultados

Seleção do estudo

Após aplicar os critérios de busca, foram encontrados 1181 estudos. Na sequência, foram excluídos os artigos duplicados e aplicados os critérios de elegibilidade. Por fim, foram incluídos para análise na presente revisão 26 artigos, conforme apresentado na Figura 1 abaixo.

Figura 1: Fluxograma de busca e composição do *corpus* do trabalho.



Características dos estudos

Dos 26 artigos incluídos, a maior parte das publicações ($n = 7$, 26,9%) corresponde aos países que compõem os Tigres Asiáticos, seguida por Estados Unidos ($n = 4$, 15,3%). Na sequência, Catar, Holanda e Reino Unido tiveram o mesmo número de publicações ($n = 2$ para cada país, 7,7%). Por fim, todos os demais países apresentaram apenas um estudo (Brasil, China, Eslováquia, Finlândia, Irã, Itália, Japão, Portugal, Tailândia).

Em relação aos anos de publicação, 2022 foi o ano com maior número de estudos ($n = 8$, 30,5%), seguido por 2021 e 2020, com 5 (19,2%) estudos publicados em cada ano; 3 trabalhos recuperados (11,5%) foram de 2019, 2 (7,7%) de 2018 e os outros três de 2016, 2012 e 2007, sendo 1 para cada ano (3,8%). Além disso, a maioria dos estudos eram

retrospectivos (n = 16, 61,5%) e 9 eram prospectivos (34,6%). Apenas 1 estudo apresentava uma parte do estudo com dados retrospectivos e outra parte com dados prospectivos. Referente ao *follow-up*, todos os estudos prospectivos apresentaram esta informação. A média de tempo de *follow-up* foi de 6 meses. Estes dados estão descritos em detalhes na Tabela 1.

Tabela 1. Caracterização dos estudos

Número do estudo	Ano de publicação	País de publicação	Desenho do estudo	Follow-up	Tempo de Follow-up
1	2022	Taiwan	Retrospectivo	não	-
2	2021	USA	Prospectivo	sim	6 meses
3	2022	Irã	Prospectivo	sim	6 meses
4	2021	Tailândia	Prospectivo	sim	6 meses
5	2019	China	Retrospectivo	não	-
6	2022	Uganda/USA	Retrospectivo	não	-
7	2022	Coreia do Sul	Retrospectivo	não	-
8	2007	Singapura	Prospectivo	sim	6 meses
9	2021	Coreia do Sul	Retrospectivo	não	-
10	2022	Portugal	Retrospectivo	não	-
11	2020	Holanda	Retrospectivo/prospectivo	sim	6 meses
12	2021	Taiwan	Retrospectivo	não	-
13	2020	Japão	Retrospectivo	não	-
14	2019	Finlândia	Retrospectivo	não	-
15	2018	USA	Retrospectivo	sim	6 meses
16	2018	Taiwan	Retrospectivo	não	-
17	2022	Itália	Prospectivo	sim	3 meses, entre 6 e 9 meses
18	2020	Brasil	Prospectivo	sim	14 dias
19	2020	Catar	Retrospectivo	não	-
20	2021	Eslováquia	Prospectivo	sim	72h, 3 meses e 6 meses
21	2012	USA	Prospectivo	sim	14 dias, 3 e 6 meses
22	2019	Reino Unido	Retrospectivo	sim	6 meses
23	2016	Holanda	Retrospectivo	sim	6 meses
24	2020	Catar	Retrospectivo	não	-
25	2022	Reino Unido	Prospectivo	sim	6 meses
26	2022	Coreia do Sul	Retrospectivo	não	-

Desfechos, amostra e técnicas de *Machine Learning*

Concernente aos desfechos investigados, a maior parte dos estudos (n=10, 38,5%) avaliou, de forma dicotômica, apenas os desfechos favoráveis, compreendidos como incapacidade moderada e boa recuperação, ou apenas os desfavoráveis, entendidos como morte, estado vegetativo ou incapacidade grave. Alguns estudos investigaram se houve mortalidade ou não, enquanto outros avaliaram se houve mortalidade intra-hospitalar. Alguns estudos (n=6, 22,8%) investigaram mais de um desfecho, conforme exposto na Tabela 2.

Tabela 2. Desfechos, amostra e técnicas de *machine learning* empregadas

Número do estudo	Desfechos de predição investigados	Composição da amostra	Números de participantes	Algoritmo de ML empregadas
1	Mortalidade e não-mortalidade	Pacientes maiores de 18 anos admitidos na sala de emergência	18249	LightGBM, MLP, RF, RL, SVM, XGBoost
2	Favorável (incapacidade moderada e boa recuperação) e desfavorável (morte, estado vegetativo ou incapacidade severa)	Adultos que tenham experimentado TCE grave ou moderado causado por trauma contuso	831	XGBoost
3	Favorável (incapacidade moderada e boa recuperação) e desfavorável (morte, estado vegetativo ou incapacidade severa)	Pacientes admitidos na unidade de cuidado intensivo neurológica	2381	RF, RL, SVM
4	Favorável (incapacidade moderada e boa recuperação) e desfavorável (morte, estado vegetativo ou incapacidade severa)	pacientes com TCE que tinha menos de 15 anos	828	ANN, K-NN, NB, RF, RL, SVM
5	Mortalidade e não-mortalidade	pacientes internados com TCE no Departamento de Cirurgia de Trauma	117	BaT, BT, CG-SVM, C-KNN, Co-KNN, C-SVM, CT, Cu-KNN, DL, FG-SVM, F-KNN, L-SVM, MG-SVM, M-KNN, MT, QD, Q-SVM, RL, RUSBT, SD, S-KNN, ST, W-KNN
6	Favorável (incapacidade moderada e boa recuperação) e desfavorável (morte, estado vegetativo ou incapacidade severa)	Todos os pacientes com TCE, conforme definido pela apresentação com traumatismo craniano, foram incluídos sem restrição de idade	2164	DNN, LRnet, SNN

Número do estudo	Desfechos de predição investigados	Composição da amostra	Números de participantes	Algoritmo de ML empregadas
7	Diagnóstico de TCE, TCE com hemorragia ou ferimento intracranial, TCE sem alta hospitalar e TCE com morte Favorável (incapacidade moderada e boa recuperação) e	Foram incluídas pessoas maiores de 15 anos com trauma severo	1169	EN, LR, RF, SVM, XGBoost
8	desfavorável (morte, estado vegetativo ou incapacidade severa)	Pacientes com TCE grave não-penetrante	513	AD, ANN, BN, DT, RL
9	(1) desfecho medido na alta (2) mortalidade intra-hospitalar (3) LOS no hospital (4) necessidade de intervenção cirúrgica	Vítimas de TCE, menores de 19 anos, submetidas a TC cerebral sem contraste	58	CatBoost
10	Mortalidade e não-mortalidade	Pacientes pediátricos, < 18 anos vítimas de TCE	300	ANN, K-NN, RF, XGBoost
11	Os desfechos previstos foram mortalidade de 6 meses e desfecho desfavorável	TCE moderado a grave	12397	ANN, GBM, RF, RL, RLa, RR, SVM
12	Mortalidade intra-hospitalar	paciente < 16 anos e diagnosticado com TCE	3331	J48, K-NN, NB, REP Tree, RF, RT, SVM
13	Favorável (incapacidade moderada e boa recuperação) e desfavorável (morte, estado vegetativo ou incapacidade severa)	pacientes consecutivos com TCE maiores de 10 anos	232	DT, ET, GBoosting, GNB, MNB, RF, RLa, RR, SVM
14	Mortalidade e não-mortalidade	Pacientes adultos com TCE (16 anos ou mais) que foram admitidos (dentro de 24 horas após o trauma)	472	RL
15	Favorável (incapacidade moderada e boa recuperação) e desfavorável (morte, estado vegetativo ou incapacidade severa)	Pacientes de 0 a 18 anos de idade com TCE leve a grave	565	ANN
16	Mortalidade e não-mortalidade	Pacientes adultos com idade > 20 anos e internados para tratamento de TCE moderado e grave	2059	ANN, DT, NB, RL, SVM
17	Favorável (incapacidade moderada e boa recuperação) e desfavorável (morte, estado vegetativo ou incapacidade severa)	Pacientes com idade > 18 anos admitidos no centro de reabilitação intensiva de um instituto de saúde para tratamento de TCE moderado e grave	102	DT, K-NN, NB, SVM
18	óbito em 14 dias mortalidade hospitalar o número de dias passados na UTI número de dias passados no hospital	Pacientes com idade igual ou superior a 14 anos que apresentavam anormalidade intracraniana na tomografia computadorizada (TC) inicial da cabeça	517	ANN, BM, Boosting, DA, DT, GLM, MARS, PLS, RF
19	mortalidade intra-hospitalar	Apenas pacientes adultos (≥ 14 anos de idade) que sofreram TCE	1620	ANN, SVM

Continuação da Tabela 2.

Número do estudo	Desfechos de predição investigados	Composição da amostra	Números de participantes	Algoritmo de ML empregadas
20	mortalidade e desfecho favorável (incapacidade moderada e boa recuperação) ou desfavorável (morte, estado vegetativo ou incapacidade severa)	Pacientes adultos (com idade igual ou superior a 18 anos) submetidos a uma descompressão crânica primária para uma hemorragia intracraniana pós-traumática expansiva com volume superior a 25 mL (tipo Marshall VI em todos os pacientes)	40	CRF, SRF
21	Mortalidade e não-mortalidade estar internado há 14 dias ou em UTI há 14 dias Favorável (incapacidade moderada e boa recuperação) e desfavorável (morte, estado vegetativo ou incapacidade severa) aos 3 e 6 meses Favorável (incapacidade moderada e boa recuperação) e desfavorável (morte, estado vegetativo ou incapacidade severa)	Foram incluídos pacientes adultos (com mais de 17 anos) com TCE grave	52	1-NN, 3-NN, CCP, DLD, NC, SVM
22	Favorável (incapacidade moderada e boa recuperação) e desfavorável (morte, estado vegetativo ou incapacidade severa)	Pacientes com 16 anos ou menos, que sofreram TCE grave	94	LiR, SVM
23	Mortalidade e não-mortalidade	Pacientes acometidos por TCE moderado ou grave	11026	CART, NN, RF, RL, SVM
24	mortalidade intra-hospitalar	Pacientes adultos (> 14 anos) que sofreram TCE com escore abreviado de gravidade da lesão para região da cabeça (HAIS) ≥ 3 .	785	ANN, RL
25	Favorável (incapacidade moderada e boa recuperação) e desfavorável (morte, estado vegetativo ou incapacidade severa)	Pacientes internados em UTI com 16 anos ou mais	1550	CPMDeepMN, CPMDeepOR, CPMMNLR, CPMPLR
26	Morte precoce (dentro de 14 dias do TCE)	Pacientes com TCE internados maiores de 18 anos	423	CRASH model, RF, RL, SVM

Continuação da Tabela 2.

Por fim, foram utilizados 59 algoritmos diferentes de *machine learning*. Dentre elas, as mais frequentes foram *Random Forest* (n = 14), *Support Vector Machine* (N = 14), Regressão logística (n = 14) e *Neural Networks* (n = 13). Os estudos ainda utilizaram *K-Nearest Neighbors* (n = 6), *Decision Tree* (n = 5).

Considerações finais

Considerando o impacto do TCE na morbimortalidade da população mundial, é imprescindível investigar as características epidemiológicas das vítimas de TCE, bem como acompanhar a evolução tecnológica como uma estratégia útil no monitoramento e tomada de

decisões clínicas. As técnicas de *machine learning* têm sido apontadas como promissoras na identificação de variáveis com capacidade de predição prognóstica em condições de doença como o TCE.

Os dados aqui representados estão, em linhas gerais, em consonância a outros estudos, ratificando a distribuição majoritária de casos de TCE em homens de meia idade, vítimas de TCE por acidentes automobilísticos e quedas. Além disso, percebe-se o avanço na área de ML, especialmente nos últimos cinco anos.

Estes dados demonstram que ML pode se tornar forte aliada nas tomadas de decisões, favorecendo resoluções mais seguras e em menor tempo. Compreende-se que o grande avanço técnico-científico de uma área é marcado, também, por uma pluralidade de procedimentos. Isto fica evidente ao examinar as técnicas utilizadas, em que uma grande gama de algoritmos é usada.

Por fim, apesar das divergências metodológicas dos estudos contidos nesta revisão, os frutos dela apontam para uma grande utilidade das técnicas de *machine learning* para predição de mortalidade em TCE, tanto quanto as técnicas tradicionais de regressão logística. Aponta-se como limitação deste estudo a não comparação entre os diferentes processos de validação e calibração das técnicas de *machine learning* dos estudos.

Perspectiva

Como perspectivas deste estudo, aponta-se:

1. A atualização da busca utilizando o descritor inteligência artificial;
2. Avaliar o risco de viés dos estudos, por meio da *Newcastle-Ottawa Scale* (NOS);
3. Realização de meta-análise, segundo os dados permitam.
4. Intenção de publicar a revisão em jornal de impacto na área após tradução para a língua inglesa.

Referências

- Almeida, C. E. R., Filho, J. L. S., Dourado, P. A. M. G., Dellaretti, M. A., & Costa, B. S. (2016). Traumatic brain injury epidemiology in Brazil. *World Neurosurgery*, *87*, 540-547. <http://dx.doi.org/10.1016/j.wneu.2015.10.020>
- Amorim, R. L., Oliveira, L. M., Malbouisson, L. M., Nagumo, M. M., Simoes, M., Miranda, L., Bor-Seng-Shu, E., Beer-Furlan, A., Andrade, A. F., Rubiano, A. M., Teixeira, M. J., Koliaç, A. G., & Paiva, W. S. (2020). Prediction of early TBI mortality using a machine learning approach in a LMIC population. *Frontiers in Neurology*, *10*(1366), 1-10. <https://doi.org/10.3389/fneur.2019.01366>
- Areas, F. Z., Schwarzbald, M. L., Diaz, A. P., Rodrigues, I. K., Souza, D. S., Ferreira, C. L., Quevedo, J., Lin, K., Kupek, E., Ritter, C., Pizzol, F. D., & Walz, R. (2019). Predictors of hospital mortality and the related burden of disease in severe traumatic brain injury: a prospective multicentric study in Brazil. *Frontiers in Neurology*, *10*(432), 1-8. <https://doi.org/10.3389/fneur.2019.00432>
- Capizzi, A., Woo, J., & Verduzco-Gutierrez, M. (2020). An overview of epidemiology, pathophysiology, and medical management. *Medical Clinics of North America*, *104*, 213-238. <https://doi.org/10.1016/j.mcna.2019.11.001>
- Cardoso, M. G. F., Faleiro, R. M., Paula, J. J., Kummer, A., Caramelli, P., Teixeira, A. L., Souza, L. C., & Miranda, A. S. (2019). Cognitive impairment following acute mild traumatic brain injury. *Frontiers in Neurology*, *10*(198), 1-9. <https://doi.org/10.3389/fneur.2019.00198>
- Carteri, R. B. K., & Silva, R. A. (2021). Incidência hospitalar de traumatismo craniocéfálico no Brasil: uma análise dos últimos 10 anos. *Revista Brasileira de Terapia Intensiva*, *33*(2), 282-289. <http://dx.doi.org/10.5935/0103-507X.20210036>

- Choi, R. Y., Coyner, A. S., Kalpathy-Cramer, J., Chiang, M. F., & Campbell, P. (2020). Introduction to Machine Learning, Neural Networks, and Deep Learning. *TVST*, 9(2), 1-12. <https://doi.org/10.1167/tvst.9.2.14>
- Galgano, M., Toshkezi, G., Qiu, X., Russel, T., Chin, L., & Zhao, L. (2017). Traumatic brain injury: current treatment strategies and future endeavors. *Cell Transplantation*, 26(7), 1118-1130. <http://dx.doi.org/10.1177/0963689717714102>
- Higgins, J. P. T., & Thomas, J. (2022). *Cochrane handbook for systematic reviews of interventions*. Version 6.3. The Cochrane Collaboration. Recuperado em 23 de setembro de 2022, de: <https://training.cochrane.org/handbook>
- Irimia, A., Maher, A. S., Chaudhari, N. N., Chowdhury, N. F., & Jacobs, E. B. (2020). Acute cognitive deficits after traumatic brain injury predict Alzheimer's disease-like degradation of the human default mode network. *GeroScience*, 42(5), 1411-1429. <https://doi.org/10.1007/s11357-020-00245-6>
- Magalhães, A. L. G., Barros, J. L. V. M., Cardoso, M. G. F., Rocha, N. P., Faleiro, R. M., Souza, L. C., Miranda, A. S., & Teixeira, A. L. (2022). Traumatic brain injury in Brazil: an epidemiological study and systematic review of the literature. *Arquivos de Neuro-Psiquiatria*, 80(4), 410-423. <https://doi.org/10.1590/0004-282X-ANP-2021-0035>
- Magalhães, A. L. G., Souza, L. C., Faleiro, R. M., Teixeira, A. L., & Miranda, A. S. (2017). Epidemiologia do traumatismo cranioencefálico no Brasil. *Revista Brasileira de Neurologia*, 53(2), 15-22. <https://doi.org/10.46979/rbn.v53i2.12305>
- Mateos-Pérez, J. M., Dadar, M., Lacalle-Aurioles, M., Iturria-Medina, Y., Zeighami, Y., & Evans, A. E. (2018). Structural neuroimaging as clinical predictor: A review of machine learning applications. *NeuroImage: Clinical*, 20, 506-522. <https://doi.org/10.1016/j.nicl.2018.08.019>

- Minace, S., Wang, Y., Aygar, A., Chung, S., Wang, X., Lui, Y. W., Fieremans, E., Flanagan, S., & Rath, J. (2019). MTBI identification from diffusion MR images using bag of adversarial visual features. *IEEE Trans Med Imaging*, 38(11), 2545-2555. <https://doi.org/10.48550/arXiv.1806.10419>
- Nascimento, S., Braga, G. T. P., Queiroz, A. V., Laureto, J. R., Campos, A. S., Macedo, J. R. D., & Silva, P. E. (2020). Perfil epidemiológico de pacientes adultos com traumatismo cranioencefálico grave na rede SUS do Distrito Federal: um estudo retrospectivo. *Revista Brasileira de Neurologia*, 56(4), 5-10. <https://doi.org/10.46979/rbn.v56i4.40224>
- Papp, L., Pötsch, N., Grahovac, M., Schmidbauer, V., Woehrer, A., Preusser, M., Mitterhauser, M., Kiesel, B., Wadsak, W., Beyer, T., Hacker, M., & Traub-Weidinger, T. (2018). Glioma survival prediction with combined analysis of in vivo ¹¹C-MET PET features, ex vivo features, and patient features by supervised machine learning. *Journal of Nuclear Medicine*, 59(9), 892-899. <https://doi.org/10.2967/jnumed.117.202267>
- Rostowsky, K. A., & Irimia, A. (2021). Acute cognitive impairment after traumatic brain injury predicts the occurrence of brain atrophy patterns similar to those observed in Alzheimer's disease. *GeroScience*, 43(4), 2015-2039. <https://doi.org/10.1007/s11357-021-00355-9>
- Sakai, K., & Yamada, K. (2018). Machine learning studies on major brain diseases: 5-year trends of 2014–2018. *Japanese Journal of Radiology*, 37(1), 34-72. <https://doi.org/10.1007/s11604-018-0794-4>
- Santos, C. M. C., Pimenta, C. A. M., & Nobre, M. R. C. (2007). A estratégia PICO para a construção da pergunta de pesquisa e busca de evidências. *Revista Latino-Americana de Enfermagem*, 15(3), 1-4. <https://doi.org/10.1590/S0104-11692007000300023>

- Silva, D. S., Oliveira, M. T. S., Maia, M. S., Lago, M. S., Pinheiro, E. N. S., Botelho, P. M., Lobo, J. O., Oliveira, D. F., Picanço, C. M., & Mercês, M. C. (2019). Morbimortalidade hospitalar por traumatismo cranioencefálico na Bahia entre 2008 a 2017. *Enfermagem Brasil*, 18(5), 665-674. <https://doi.org/10.33233/eb.v18i5.3075>
- Silva, L. C. A. (2018). *Características clínico-epidemiológicas das ocorrências envolvendo traumatismo cranioencefálico (TCE) atendidas em um hospital universitário* [Tese de Doutorado, Universidade de São Paulo]. Biblioteca Digital USP. Recuperado em 23 de setembro de 2022, de: <https://teses.usp.br/teses/disponiveis/17/17139/tde-08112018-153237/pt-br.php>
- Thurman, D. J., Kraus, J. F., & Romer, C. J. (1995). Standards for surveillance of neurotrauma. Centers for Disease Control and Prevention.
- Tunthanathip, T., & Oearsakul, T. (2021). Application of machine learning to predict the outcome of pediatric traumatic brain injury. *Chinese Journal of Traumatology*, 24(6), 350-355. <https://doi.org/10.1016/j.cjtee.2021.06.003>
- Tunthanathip, T., Sae-Heng, S., Oearsakul, T., Sakarunchai, I., Kaewborisutsakul, A., & Taweksomboonyat, C. (2019). Machine learning applications for the prediction of surgical site infection in neurological operations. *Neurosurgical Focus*, 47(2). <https://doi.org/10.3171/2019.5.FOCUS19241>
- Valdebenito, J., Medina, F. (2019). Machine learning approaches to study glioblastoma: a review of the last decade of applications. *Cancer Rep*, 2(e1226), 1-15. <https://doi.org/10.1002/cnr2.1226>
- Vella, M. A., Crandall, M., & Patel M. (2017). Acute management of traumatic brain injury. *Surgical Clinics of North America*, 97(5), 1015-1030. <http://dx.doi.org/10.1016/j.suc.2017.06.003>

Apêndice

Apêndice A – Protocolo de diretrizes para o estudo

Identificação das evidências de pesquisa	<p>Pergunta de pesquisa: Quais são as estratégias de <i>machine learning</i> mais utilizadas para predição de mortalidade decorrente de Traumatismo Cranioencefálico?</p> <p>Descritores: <i>traumatic brain injury</i> e <i>head trauma</i>, combinados com <i>machine learning</i> e <i>deep learning</i></p> <p>Idiomas: português, inglês e espanhol</p>
Seleção dos estudos	Dois pesquisadores independentes farão a coleta dos dados nas bases indexadas. Excluindo os títulos duplicados, os pesquisadores avaliarão título e resumo, de acordo com os critérios de elegibilidade. Posteriormente os artigos serão lidos na íntegra para análise e composição do <i>corpus</i> da revisão. Caso haja discordância quanto à inclusão ou exclusão de algum artigo, uma terceira pesquisadora será consultada.
Extração dos dados	A extração dos dados será feita por um dos pesquisadores, com auxílio de um protocolo construído para este fim, conforme apêndice B. Para tabulação dos dados, será utilizado o <i>software</i> Excel ou similar.
Síntese dos dados	Os dados serão sumarizados de acordo com o apêndice B, sendo categorizados, especialmente, no que concerne aos tipos de predições realizadas e as estratégias de <i>machine learning</i> utilizadas para as predições.
Disseminação	Esta revisão refere-se a um projeto de mestrado, compondo, portanto, a dissertação de mestrado. Além disso, pretende-se divulgar os resultados em formato de artigo científico, em revista de alto impacto que permita maior alcance das informações sumarizadas na revisão.

