

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
INSTITUTO DE BIOTECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM BIOTECNOLOGIA

TALLES HENRIQUE CAIXETA

**DESENVOLVIMENTO DE ALGORITMO DE
INTELIGÊNCIA ARTIFICIAL PARA DETECÇÃO DE
HEMORRAGIAS INTRACRANIANAS PÓS-TRAUMAS
CRANIOENCEFÁLICOS E SEUS POTENCIAIS
BENEFÍCIOS NO SUS FÁCIL**

PATOS DE MINAS – MG
DEZEMBRO DE 2021

TALLES HENRIQUE CAIXETA

**DESENVOLVIMENTO DE ALGORITMO DE
INTELIGÊNCIA ARTIFICIAL PARA DETECÇÃO DE
HEMORRAGIAS INTRACRANIANAS PÓS-TRAUMAS
CRANIOENCEFÁLICOS E SEUS POTENCIAIS
BENEFÍCIOS NO SUS FÁCIL**

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Biotecnologia, Mestrado Acadêmico em Biotecnologia, com vistas à obtenção do título de Mestre em Biotecnologia.

Orientação: Prof. Dr. Laurence Rodrigues do Amaral

PATOS DE MINAS – MG

DEZEMBRO DE 2021

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Bibliotecas da UFU, MG, Brasil.

C138d
2022 Caixeta, Talles Henrique, 1978-
Desenvolvimento de algoritmo de inteligência artificial para detecção de hemorragias intracranianas pós-traumas cranioencefálicos e seus potenciais benefícios no SUS Fácil [recurso eletrônico] / Talles Henrique Caixeta. - 2022.

Orientador: Laurence Rodrigues do Amaral.

Dissertação (mestrado) - Universidade Federal de Uberlândia.
Programa de Pós-Graduação em Biotecnologia.

Modo de acesso: Internet.

Disponível em: <http://doi.org/10.14393/ufu.di.2022.5318>

Inclui bibliografia.

Inclui ilustrações.

1. Biotecnologia. I. Amaral, Laurence Rodrigues do, 1978-, (Orient.).
II. Universidade Federal de Uberlândia. Programa de Pós-Graduação em Biotecnologia. III. Título.

Glória Aparecida
Bibliotecária - CRB-6/2047



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
 Coordenação do Programa de Pós-Graduação em Biotecnologia
 Av. Getúlio Vargas, 230, 3º andar, Sala 308 - Bairro Centro, Patos de Minas-MG, CEP 38700-128
 Telefone: (34) 3823-3714 - Ramal 39 - www.ppgbiotec.ibtec.ufu.br - ppgbiotec@ibtec.ufu.br



ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Biotecnologia				
Defesa de:	Dissertação de Mestrado Acadêmico				
Data:	22 de dezembro de 2021	Hora de início:	08:57	Hora de encerramento:	10:52
Matrícula do Discente:	42012BTC012				
Nome do Discente:	Talles Henrique Caixeta				
Título do Trabalho:	DESENVOLVIMENTO DE ALGORITMO DE INTELIGÊNCIA ARTIFICIAL PARA DETECÇÃO DE HEMORRAGIAS INTRACRANIANAS PÓS TRAUMAS CRANIOENCEFÁLICO E SEUS POTENCIAIS BENEFÍCIOS NO SUS FÁCIL				
Área de concentração:	Biociência				
Linha de pesquisa:	Bioinformática e Biologia Molecular aplicada à genômica, transcriptômica e proteômica				
Projeto de Pesquisa de vinculação:					

Reuniu-se por Webconferência, Campus Patos de Minas, da Universidade Federal de Uberlândia, a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Biotecnologia, assim composta: Professores Doutores: Fernando Luiz Rolemberg Dantas, Matheus de Souza Gomes e Laurence Rodrigues do Amaral, orientador do discente.

Iniciando os trabalhos o presidente da mesa, Dr. Laurence Rodrigues do Amaral apresentou a Comissão Examinadora e o candidato, agradeceu a presença do público, e concedeu ao discente a palavra para a exposição do seu trabalho. A duração da apresentação do discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir o senhor(a) presidente concedeu a palavra, pela ordem sucessivamente, aos(às) examinadores(as), que passaram a arguir o(a) candidato(a). Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o(a) candidato(a):

Aprovado.

Esta defesa faz parte dos requisitos necessários à obtenção do título de Mestre .

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

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

Documento assinado eletronicamente por **Laurence Rodrigues do Amaral, Professor(a) do**



Magistério Superior, em 22/12/2021, às 10:54, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Matheus de Souza Gomes, Membro de Comissão**, em 22/12/2021, às 10:58, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Fernando Luiz Rolemberg Dantas, Usuário Externo**, em 22/12/2021, às 10:59, 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://www.sei.ufu.br/sei/controlador_externo.php?](https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0)

[acao=documento_conferir&id_orgao_acesso_externo=0](https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **3272052** e o código CRC **23141218**.

TALLES HENRIQUE CAIXETA

**DESENVOLVIMENTO DE ALGORITMO DE INTELIGÊNCIA ARTIFICIAL PARA
DETECÇÃO DE HEMORRAGIAS INTRACRANIANAS PÓS-TRAUMAS
CRANIOENCEFÁLICOS E SEUS POTENCIAIS BENEFÍCIOS NO SUS FÁCIL**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Biotecnologia, Mestrado Acadêmico em Biotecnologia, com vistas à obtenção do título de Mestre em Biotecnologia.

Aprovado em: ___/___/___

BANCA EXAMINADORA

Prof. Dr. Laurence Rodrigues do Amaral

Prof. Dr. Matheus de Souza Gomes

Prof. Dr. Fernando Luiz Rolemberg Dantas

PATOS DE MINAS – MG

2021

AGRADECIMENTOS

À Deus, por todas as oportunidades.

À minha esposa Katiúscia, pelo amor incondicional.

Aos meus filhos Pedro, José e João, abraços e sorrisos essenciais.

Ao meu pai Élcio, por fomentar-nos sonhar.

À minha mãe Vilma, por incentivar-nos sonhar.

Aos irmãos Fred e Igor, por ousar sonhar.

Ao professor Laurence, por ensinar-me sonhar.

Ao Vitor, por juntamente sonhar.

Ao Eurípedes e demais técnicos em Radiologia, por apoiar-nos sonhar.

Aos bons e velhos amigos, pois não se sonha só.

Ao meu irmão Roni, mãos abençoadas, por todos os ensinamentos.

Às Diretorias dos Hospitais Vera Cruz e Imaculada Conceição, por instrumentar-nos sonhar.

Aos colegas de profissão, pelos essenciais incentivos.

Aos professores do PPGBIOTEC – UFU, por ensinar-nos mesmo em grande adversidade.

À Medicina, pelos vinte anos de transformação e aperfeiçoamento.

Em especial aos meus PACIENTES, sem vocês nada disso seria possível!

Dedico às crianças que estudam em escolas públicas.

“ Mirror, mirror, here I stand. Who is the fairest in the land ? ”
Wilhelm Karl Grimm

RESUMO

O estudo e utilização da Inteligência Artificial (IA) na medicina têm crescimento exponencial. Ferramentas auxiliares à identificação de potenciais ameaças à vida e de priorização de casos poderiam ser benéficas na condução de Traumas Cranioencefálicos (TCEs) no âmbito do Sistema Único de Saúde (SUS). Estes são problemas de saúde pública, frequentemente resultando em Hemorragias Intracranianas (HICs) de elevada morbimortalidade e custos socioeconômicos, sobretudo quando não tratadas em tempo hábil. Em Minas Gerais, quando incidem em municípios de baixa complexidade hospitalar, sem neurocirurgiões, radiologistas ou tomografias computadorizadas (TCs), necessitam por mecanismo de hierarquização transferir seus pacientes usando-se a plataforma de regulação de leitos SUSFÁCIL (SF). Retardos na identificação e cadastros dos casos graves na origem, da sua análise por médicos reguladores nas centrais de regulação SF, poderiam ser amenizados com a potencial inserção de algoritmo de IA capaz de reconhecer automaticamente HICs em TCs nos locais de ocorrência, agregando agilidade para a detecção e priorização de casos ameaçadores à vida. Este trabalho propõe o desenvolvimento de um algoritmo de identificação de HICs em TCs e a análise dos seus potenciais benefícios no contexto do SF. Após coleta, processamento e formulação de datasets contendo imagens de TCs de crânio normais e com HICs, utilizou-se o *software* Orange® para treinamento, validação e teste do seu reconhecimento por modelos de Redes Neurais Artificiais (ANN), Máquinas de Vetores de Suporte (SVM), Florestas Aleatórias (*Random Forests*) e *K – Nearest- Neighbors* (KNN). O modelo de ANN apresentou resultados ligeiramente superiores aos demais modelos nas etapas de Treinamento / Validação e Teste ($AUC = 1.000$, $CA = 0.998$, $FI = 0.998$, $Precisão = 0.998$ e $Recall = 0.998$, e $AUC = 0.987$, $CA = 0.930$, $FI = 0.930$, $Precisão = 0.931$ e $Recall = 0.930$ respectivamente), conseguindo atingir o objetivo proposto para o conjunto de imagens utilizadas. A formulação de datasets mais robustos tornam-se necessários para seu uso prático e o aperfeiçoamento e emprego de algoritmos de IA devem ser incentivados.

Palavras-chave: inteligência artificial; trauma cranioencefálico; hemorragias intracranianas; aprendizado de máquina; Sistema Único Saúde; Sus Fácil.

ABSTRACT

The study and use of Artificial Intelligence (AI) in medicine has grown exponentially. Auxiliary tools for identifying potential threats to life and prioritizing cases could be beneficial in the management of Traumatic Brain Injuries (TBIs) within the scope of the Unified Health System (SUS). These are public health problems, often resulting in Intracranial Hemorrhages (ICH) with high morbidity and mortality and socioeconomic costs, especially when not treated in a timely manner. In Minas Gerais, when they focus on cities with low hospital complexity, without neurosurgeons, radiologists, or computed tomographies (CTs), they need to transfer their patients, using the SUSFÁCIL (SF) bed regulation platform, through a hierarchical mechanism. The delay in the identification and registration of serious cases at the origin, their analysis by regulators in the SF regulation centers, could be alleviated with the potential insertion of an AI algorithm capable of automatically recognizing HICs in CTs at the origin sites, thus adding agility for the detection and prioritization of life-threatening cases. This work proposes the development of an ICH identification algorithm in CT and the analysis of its potential benefits in the context of SF. After collecting and processing data sets images containing normal and HIC skull CTs, Orange® Software was used for training, validation and testing of their recognition by Artificial Neural Network (ANN) models, Support Vector Machines (SVM) and K – Nearest-Neighbors (KNN). The ANN model presented slightly better results than the other models in the Training / Validation and Testing stages (AUC = 1,000, CA = 0.998, F1 = 0.998, Accuracy = 0.998 and Recall = 0.998, and AUC = 0.987, CA = 0.930, F1 = 0.930, Precision = 0.931 and Recall = 0.930 respectively) achieving the proposed objective for the set of images used. The formulation of more robust datasets becomes necessary for a practical use and AI algorithms improvement and use should be encouraged.

Keywords: artificial intelligence; brain trauma injury; intracranial hemorrhages; machine learning; Unified Health System; Sus Fácil.

LISTA DE FIGURAS

Figura 1: Os vários tipos de Inteligências Artificiais e a subdivisão do <i>Machine Learning</i>	11
Figura 2: <i>Trecharad More, Jonh McCarthy, Marvin Minsky, Oliver Selfridg e Ray Solomonoff,</i> Cinquentenário do <i>Dartmont Project</i>	12
Figura 3: Paralelo histórico entre IA e o desenvolvimento da Radiologia.....	13
Figura 4: Crescimento das publicações médicas em IA.....	14
Figura 5: Algumas diferenças e aplicações médicas do <i>Machine Learning</i>	19
Figura 6: Arquitetura básica do Aprendizado Superficial e Profundo de Máquinas.....	20
Figura 7: Exemplo de <i>Machine Learnings</i> supervisionados e não supervisionados.....	21
Figura 8: Inteligência Artificial, ML e DL: sumário.....	22
Figura 9: Macrorregiões de Saúde / MG.....	25
Figura 10: Exemplo de longa distância de transferência.....	26
Figura 11: Racionalização do fluxo de regulação de leitos e alguns problemas.....	26
Artigo Figura 1: Os vários tipos de IA e a subdivisão do <i>Machine Learning</i>	35
Artigo Figura 2: Paralelo histórico entre IA e o desenvolvimento da Radiologia.....	36
Artigo Figura 3: Crescimento das publicações médicas em IA.....	37
Artigo Figura 4: Origem e Notação de Datasets	42
Artigo Figura 5: Fluxo do processamento de dados no algoritmo: Importação Imagens.....	43
Artigo Figura 6: Fluxo do processamento de dados no algoritmo: Incorporação de Imagens.....	44
Artigo Figura 7: Fluxo do processamento de dados no algoritmo: Modelos de <i>Machine Learning</i>	45
Artigo Figura 8: Fluxo do processamento de dados no algoritmo: <i>Test and Score</i>	46
Artigo Figura 9: Etapas de processamento de dados pelo algoritmo proposto.....	46
Artigo Figura 10: Resultados obtidos na Etapa Treinamento e Validação.....	47
Artigo Figura 11: Resultados obtidos na Etapa Teste:.....	48
Artigo Figura 12: Áreas Sob a Curva ROC na Etapa Teste.....	49
Artigo Figura 13: Análise de Calibração na Etapa Teste.....	49
Artigo Figura 14: Algumas diferenças e aplicações médicas do <i>Machine Learning</i>	52
Artigo Figura 15: Arquitetura básica do Aprendizado Superficial e Profundo de Máquinas.....	52
Artigo Figura 16: Exemplo de <i>Machine Learning</i> supervisionados e não supervisionados.....	53
Artigo Figura 17: Inteligência Artificial, ML e DL: Sumário.....	54
Artigo Figura 18: Macrorregiões de Saúde / MG.....	58
Artigo Figura 19: Exemplo de longa distância de transferência.....	58
Artigo Figura 20: Racionalização do fluxo de regulação de leitos e alguns problemas.....	60

LISTA DE ABREVIATURAS E SIGLAS

AI: *Artificial Intelligence*.

ANN: *Artificial Neural Networks* / Redes Neurais Artificiais.

AUC: métrica, área sob a Curva Característica de Operação do Receptor / Curva ROC

CA: métrica, acurácia.

CDC: *Center for Disease Control and Prevention*.

CNN: *Convolutional Neural Networks* / Redes Neurais Convolucionais.

DL: *Deep Learning* / Aprendizado Profundo de Máquinas.

EUA: Estados Unidos da América.

F1 Score: métrica, média harmônica entre *Recall* e Precisão.

FDA: *Food and Drugs Administration*.

HICs: Hemorragias Intracranianas pós-Trauma Cranioencefálico.

IA: Inteligência Artificial.

MG: Estado de Minas Gerais.

ML: *Machine Learning*. / Aprendizado de Máquinas.

NLP: *Natural Language Process* / Processamento Linguagem Natural.

NN: *Neural Network* / *Single Layer Feedforward Neural Network*.

PET-CT: *Positron Emission Tomography – Computed Tomography*.

PRECISION: métrica, Precisão. O mesmo que Valor Preditivo Positivo.

KNN: *K- Nearest Neighbors* / Vizinhos Próximos.

PubMed: base de dados de publicação de periódicos médicos americana

RECALL: métrica, Revocação. Mesmo que sensibilidade.

RNN: *Recurrent Neural Network* / Redes Neurais Recorrentes.

ROC: métrica, *Receiving Operating Curve*.

SPECT: *Single-Photon Emission Computed Tomography*.

SVM: *Support Vector Machine* / Vetor de Suporte de Máquinas.

TC: Tomógrafo Computadorizado.

TCs: Tomografias Computadorizadas.

RNMs: Ressonâncias Nucleares Magnéticas

SUS: Sistema Único de Saúde.

SUS FÁCIL: software, plataforma do Sistema de Regulação de Leitos/MG.

SUMÁRIO

RESUMO.....	06
ABSTRACT.....	07
LISTA DE FIGURAS.....	08
LISTA DE ABREVIATURAS.....	09
SUMÁRIO.....	10
1 INTRODUÇÃO.....	11
1.1 Conceito de inteligência artificial.....	11
1.2 Breve histórico.....	12
1.3 Problema.....	14
1.4 Hipótese.....	15
1.5 Objetivo.....	16
1.6 Justificativa.....	17
2 REFERENCIAL TEÓRICO.....	19
2.1 Princípios básicos do aprendizado de máquinas.....	19
2.2 O <i>Machine Learning</i> nas neurociências médicas.....	22
2.3 SUS e os Traumas Encefálicos no interior.....	24
2.4 Inteligência artificial e SUSFÁCIL.....	27
3 ARTIGO.....	30
3.1 Introdução.....	34
3.2 Materiais e Métodos.....	40
3.3 Resultados.....	47
3.4 Discussão.....	51
3.5 Conclusões.....	63
3.6 Bibliografia.....	64
4 CONCLUSÃO.....	73
REFERÊNCIAS.....	74
ANEXO 1: Normas para publicação no <i>Jornal Brasileiro de Neurocirurgia</i>	80
ANEXO 2: Checklist para estudos em imagens médicas usando IA (<i>CLAIM</i>).....	87

1 INTRODUÇÃO

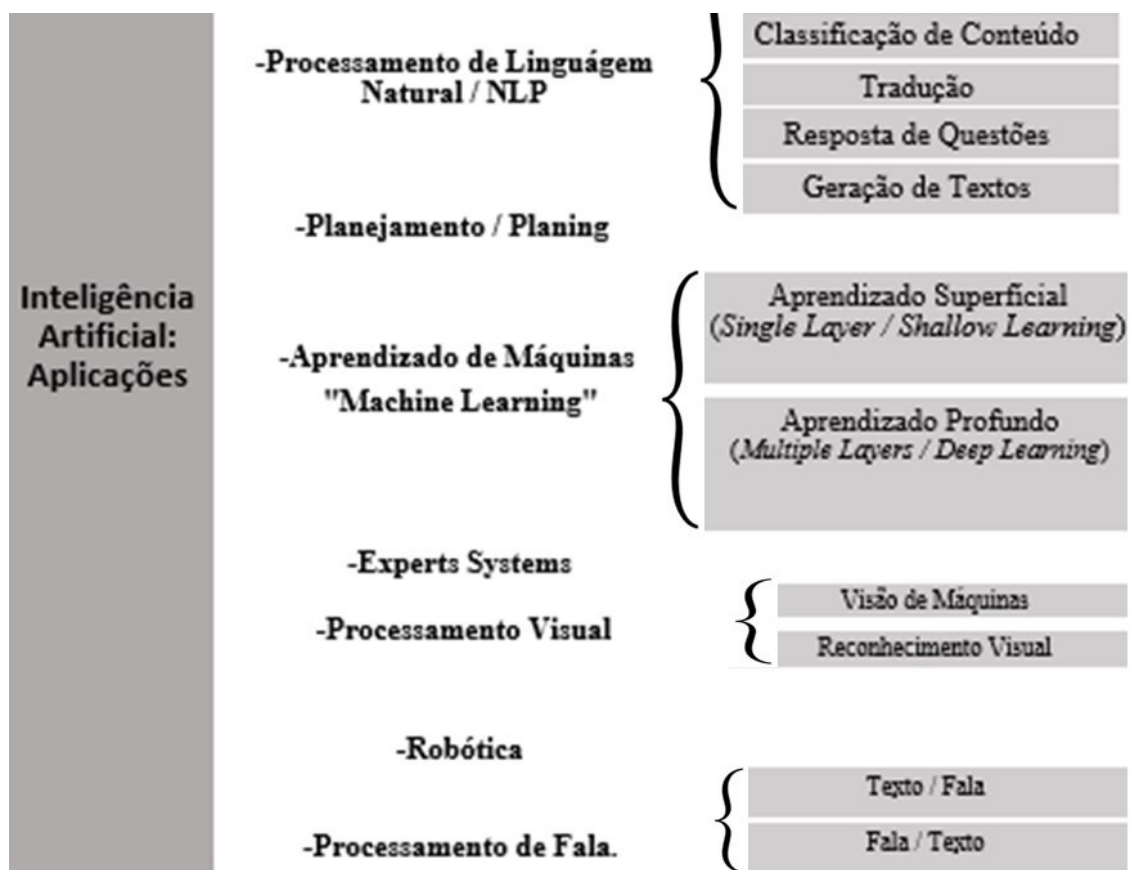
1.1 CONCEITO DE INTELIGÊNCIA ARTIFICIAL

Inteligência Artificial (IA) pode ser definida como a capacidade de uma máquina, geralmente um computador, se portar de forma semelhante ao que antes se pensava ser exclusiva da inteligência humana (RAYMOND GEIS et al., 2019).

Por mecanismos de adaptação flexível, elas conseguem interpretar dados externos, aprender modelos e utilizar-se desses aprendizados para efetuarem tarefas específicas (KAPLAN; HAENLEIN, 2019).

A IA pode ser subdividida em vários campos de pesquisa, como o Aprendizado de Máquinas (*Machine Learning*) que realiza previsões por reconhecimento de padrões de dados ou o Processamento de Linguagem Natural (*Natural Language Processing*), capaz de produzir previsões por intermédio de análise de dados de textos, conforme exemplificado na Figura 1 (LEIVA; CASARI; ÖSTBERG, 2019) (PANESAR et al., 2020).

FIGURA 1 - Os vários tipos de Inteligências Artificiais e a subdivisão do Machine Learning.



Fonte: Panesar, 2020

1.2 BREVE HISTÓRICO:

O estudo da Inteligência Artificial (IA) remonta 1956 quando os cientistas de computação *John McCarthy* e *Marvin Minsky* organizaram o *Dartmouth Summer Research Project on Artificial Intelligence*, evento aonde o termo IA foi primeiramente citado. A Figura 2 homenageia esta geração pioneira de cientistas na ocasião da celebração do quinquagésimo aniversário deste encontro (MOOR, 2006).

Nos anos 1960 houve certo desinteresse dos pesquisadores médicos pela IA, ressurgindo sua pesquisa na década seguinte com a criação do *Research Resource on Computers in Biomedicine* da Universidade Rutgers. Durante o Congresso da Academia Americana de Oftalmologia de 1976, esta iniciativa científica apresentou para a comunidade médica o *CASNET®*, primeiro protótipo de aplicativo que utiliza da IA para auxílio ao manejo do Glaucoma (VALLIANI; RANTI; OERMANN, 2019) .

Em 1992 surgem as primeiras publicações por radiologistas estudando a IA na detecção de neoplasias malignas em mamografias, denotando a abertura de uma era de crescente interesse da Radiologia pelo uso da IA (GIGER, 1993).

FIGURA 2 - Trechard More, Jonh McCarthy, Marvin Minsky, Oliver Selfridg e Ray Solomonoff: cinquentenário do Dartmont Project.

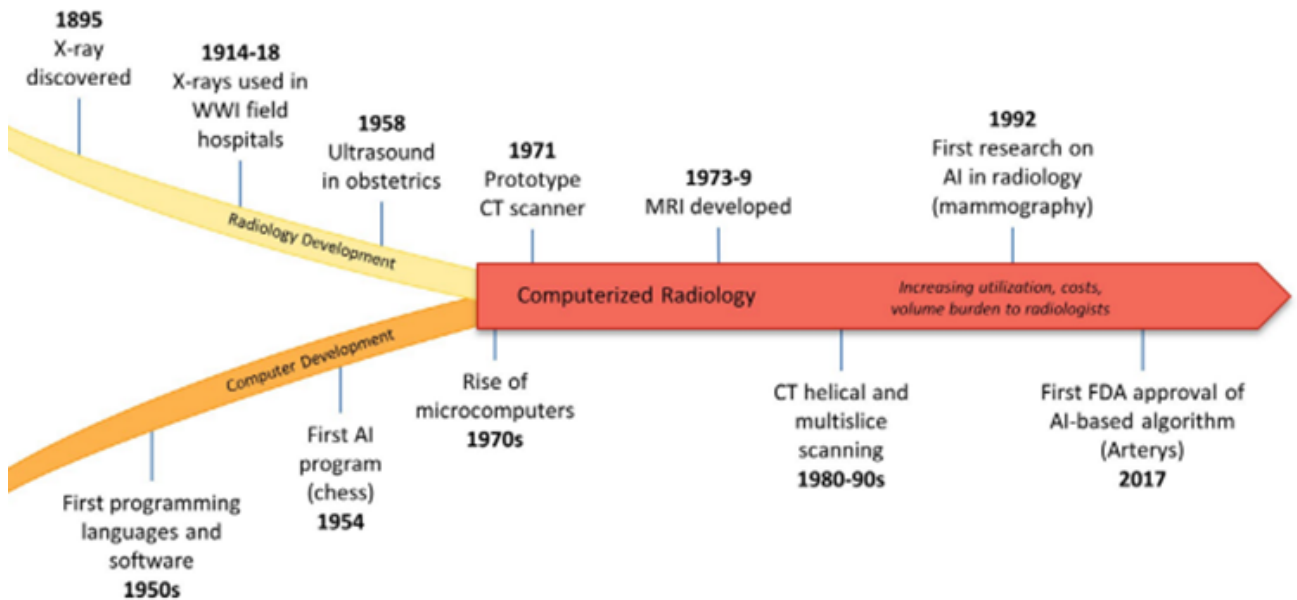


Fonte Moor, 2006.

Desde os anos 1970, quando surgiram os protótipos das Tomografias Computadorizadas (TCs), das Ressonâncias Nucleares Magnéticas (RNMs) e dos Computadores Pessoais (PCs), até chegarmos aos dias atuais houve crescente interesse em pesquisas sobre IA principalmente na Neuroradiologia. Ao longo do tempo houve um paralelo entre as crescentes melhorias dos recursos computacionais e o advento dos exames de imagens, conforme mostrado na Figura 3 (KAUL; ENSLIN; GROSS, 2020).

A abundância de recursos de imagem, de tecnologia computacional acessível e de troca de informações pela Internet, levou nos últimos cinco anos a um aumento significativo de trabalhos publicados em periódicos médicos utilizando-se de pesquisas em IA, sobretudo na neuroradiologia. A Figura 4 ilustra este crescimento (DUONG; RAUSCHECKER; MOHAN, 2020).

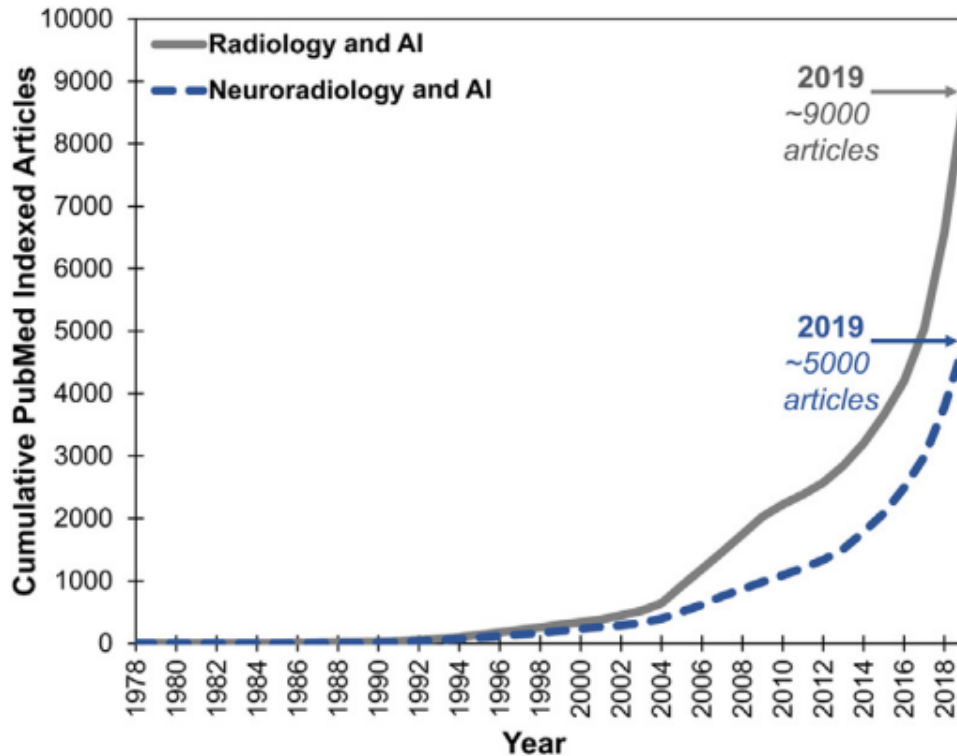
FIGURA 3 - Paralelo histórico entre IA e o desenvolvimento da Radiologia.



Fonte: Kaul, 2020.

A IA pode ser uma ferramenta útil na rápida detecção de padrões de imagem de patologias ameaçadoras a vida, como por exemplo, as Hemorragias Intracranianas (HICs) secundárias a Traumatismos Cranioencefálicos (TCEs). Em emergências, a rápida detecção de HICs é crucial em virtude do potencial de danos neurológicos severos e óbitos relacionados a sua patologia (CARNEY et al., 2017) (MONTEIRO et al., 2020) (FLANDERS et al., 2020).

FIGURA 4 - Crescimento das publicações médicas em IA.



Fonte DUONG; RAUSCHECKER; MOHAN, 2020.

1.3 PROBLEMA:

Os TCEs são patologias de ocorrência comum em nosso meio, entretanto são escassos grandes estudos epidemiológicos brasileiros. Geralmente são estudos relacionados à centros hospitalares específicos, cidades e regiões, não sendo portanto de amplitude nacional (BORDIGNON; ARRUDA, 2002) (TUDE MELO; DA SILVA; MOREIRA, 2004).

Estatísticas americanas do ano de 2010, estimaram a avaliação de cerca de 2,5 milhões de vítimas de TCEs, sendo estes responsáveis por cerca de 15% de todos os atendimentos em serviços de emergência, seja como diagnóstico primário ou secundário. Destes 20% eram casos moderados ou graves, exigindo sua internação entre 50 a 70% das ocasiões (CDC; NCIPC, 2015).

A mortalidade global dos TCEs foi estimada em cerca de 18/100.000 casos por ano. Acometem todas as faixas etárias, havendo predomínio no gênero masculino e em jovens. Houve crescimento de 62 % na incidência casos de TCEs em jovens americanos abaixo de 19 anos de idade entre os anos de 2001 e 2009, principalmente associados a práticas desportivas e recreação, denotando um problema em expansão. Os TCEs possuem altas taxas de mortalidade quando acometem idosos com mais de 75 anos. Ocorrem tanto em desenvolvidas capitais, com

centros médicos de alta complexidade, quanto em pequenas cidades, sem qualquer infraestrutura especializada. Causam grande sofrimento para as vítimas e seus familiares, possuindo elevado custo sócio-econômico, estima-se um gasto de cerca de 82 bilhões de dólares anuais com o seu tratamento (GARDNER et al., 2012) (DEFILLO, 2011) (GAUDÊNCIO; LEÃO, 2013).

Tecnologias como as Tomografias Computadorizadas (TCs) foram essenciais para a compreensão da fisiopatologia, facilitando diagnósticos, otimizando tratamentos e melhorando prognósticos (CARNEY et al., 2017).

Contudo existem fatores limitantes para sua aplicação em larga escala em nosso meio. Seu emprego em municípios pequenos, dotados de orçamentos modestos, é dificultado pelo alto custo de aquisição de aparelhos. Também são limitadores a manutenção onerosa, a contratação de profissionais técnicos e médicos especializados como radiologistas, neurocirurgiões e intensivistas, além da burocracia na sua compra e manutenção (SANTIAGO, 2007).

A aquisição e manutenção isolada de TCs para a detecção precoce destas patologias seria uma opção economicamente viável para alguns destes municípios, todavia os elevados custos com quadro pessoal não seriam compatíveis com as suas realidades orçamentárias (AZEVEDO et al., 2016).

Tendo em mãos um real problema de saúde pública, aliada à escassez de meios para o seu tratamento, teríamos disponíveis alternativas tecnológicas viáveis capazes de reduzir o impacto dos TCEs sobre a sociedade tendo em vista o cenário assistencial do SUS atual?

1.4 HIPÓTESE

O atendimento especializado aos TCEs e a pronta identificação de HICs seriam factíveis à distância por intermédio de soluções tecnológicas como a IA e a Telemedicina, não obstante a realidade atual de inexistência de TCs nos locais de ocorrência dos acidentes (GANAPATHY, 2004) (GANAPATHY; ABDUL; NURSETYO, 2018).

Este fato leva à invariável necessidade de transferência de todos os casos suspeitos, por vezes desnecessariamente centenas de quilômetros. Pacientes diagnosticados como TCEs de menor gravidade, poderiam hipoteticamente serem tratados localmente caso houvesse disponibilidade de TCs e consultoria especializada à distância. Por outro lado, as cidades detentoras de hospitais de média e alta complexidade, geralmente detêm salas de emergência e observações superlotadas, pois absorvem tanto os casos graves, quanto àqueles que a insuficiência de meios diagnósticos do interior os leva a atender (MARIANI; PÊGO-

FERNANDES, 2012) (BITTENCOURT; HORTALE, 2009).

Questionamos se a aplicação de soluções tecnológicas, como algoritmos de Aprendizado de Máquinas capazes de identificar HICs em TCs, poderiam reduzir o impacto dos TCEs sobre a sociedade, sobretudo quando aplicadas em um cenário de escassez de recursos assistenciais, como cidades com hospitais de baixa complexidade e credenciados ao SUS.

1.5 OBJETIVO

1.5.1 Objetivo Geral

Esta pesquisa visa estudar, desenvolver e empregar um algoritmo de IA para diferenciar imagens de TCs de crânio portadoras de HICs de controles normais e analisar seus potenciais benefícios no cenário assistencial do SUSFÁCIL.

1.5.2 Objetivos específicos

- 1.5.2.1 Compreender os conceitos básicos relacionados à Inteligência Artificial, Aprendizado de Máquinas, Mineração de Dados e modelos de classificação de imagens baseadas em *Machine Learning* (ML) e *Deep Learning* (DL);
- 1.5.2.2 Revisar o uso da IA nos mais variados campos de atividade médica e seus potenciais benefícios terapêuticos, sobretudo no contexto neurotraumatológico;
- 1.5.2.3 Desenvolver habilidades para construir, prospectar, anotar e anonimizar datasets de imagem;
- 1.5.2.4 Desenvolver habilidades para manejo de softwares básicos que transformam imagens clínicas em dados computacionais capazes de serem analisadas por modelos de *Machine Learning*;

- 1.5.2.5 Entender como se dá o processamento dos datasets pelos variados modelos de aprendizagem e compreender como se interpreta estatisticamente seus resultados de treinamento, validação e testes;
- 1.5.2.6 Tentar enumerar as variadas causas de dificuldade de transferências de pacientes através dos modelos de hierarquização e referência;
- 1.5.2.7 Identificar potenciais benefícios do emprego de um algoritmo de identificação de imagens anormais ou de priorização em lista no auxílio dos pacientes vítimas de TCEs no contexto assistencial do SUSFÁCIL;
- 1.5.2.8 Compreender a estrutura básica dos modelos de *Machine Learning* empregados na pesquisa: Redes Neurais Artificiais, Máquinas de Vetores de Suporte e *K – Nearest Neighbors*;
- 1.5.2.9 Incentivar os leitores quanto à existência de recursos tecnológicos como a IA, demonstrando que seu uso na vida prática é realidade em vários centros e sua pesquisa em nosso meio possa ser viável.
- 1.5.2.10 Compreender a legislação, os princípios éticos e as normativas estabelecidas em consensos para o estudo e publicação de artigos científicos empregando IA.
- 1.5.2.11 Compreender as normas básicas que devem ser observados para a publicação de artigos científicos empregando a IA, conforme Anexo 2.

1.6 JUSTIFICATIVA

O emprego de ferramentas de IA poderiam proporcionar uma melhor atenção às vítimas de TCEs, com custos potencialmente acessíveis, sobretudo se aplicadas no âmbito do Sistema Único de Saúde (SUS) (GAMEIRO et al., 2019).

Com soluções computacionais baseadas em IA, seria possível implementar uma

ferramenta para automação na detecção de HICs em localidades onde existam TCs, mas não disponham médicos especialistas (neurocirurgiões e radiologistas) fisicamente disponíveis para seu diagnóstico e condução terapêutica (CHOWDHURY; CHAKRABORTY, 2017).

Longas distâncias e graves doenças poderiam ser amenizadas por tecnologia e altruísmo dos gestores de saúde. Este recurso tecnológico seria inclusivo, econômico e ágil. Abreviaria prazos, otimizaria tratamentos e melhoraria prognósticos (RAMESH et al., 2004) (HOULTON, 2018).

2 REFERENCIAL TEÓRICO

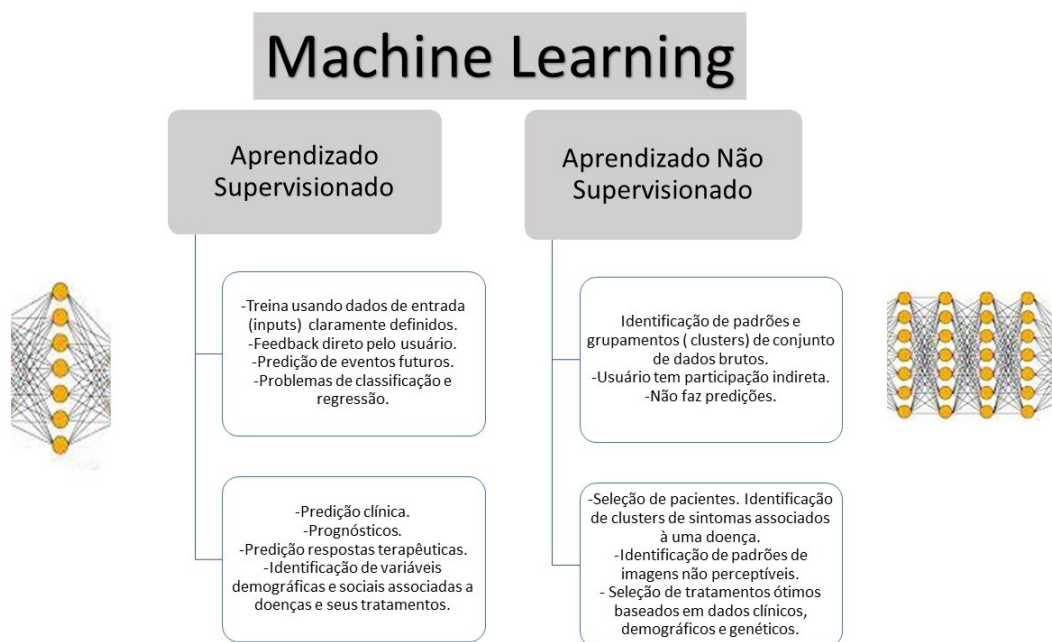
2.1 PRINCÍPIOS BÁSICOS DO APRENDIZADO DE MÁQUINAS:

Em 1994, o jornalista do periódico *Science* David H. Freedman descreveu para a Sociedade Americana de Avanços da Ciência que “havia um florescente romance entre a substância cinzenta e o silício”. Descrevia-se então que modelos computacionais poderiam “simular” a atividade de neurônios humanos, remetendo-nos ao conceito de Redes Neurais Artificiais (*Artificial Neural Networks* - ANN ou simplifiadamente *Neural Networks*) (FREEDMAN, 1994).

Desde então inúmeros trabalhos foram produzidos com uso de IA na medicina. Em 2017, o primeiro *software* baseado em IA chamado *Arterys*®, foi aprovado pelo *Food And Drugs Administration* (FDA) para uso comercial. Estima-se que até 2025 cerca de 109 bilhões de dólares sejam investidos na produção de *softwares* aplicando modelos de ML e DL para o mercado da saúde (CROWLEY, 2017) (COHEN; NAHED; SHETH, 2013).

O Aprendizado de Máquina ou “*Machine Learning*” (ML) é a modalidade de IA mais utilizada em pesquisas médicas. Utiliza algoritmos e modelos estatísticos treinados em dados de amostras para identificar padrões e fazer previsões a partir de novos dados. Abaixo exemplificamos alguns usos do ML na Figura 5 (PANESAR et al., 2020).

FIGURA 5 - Algumas diferenças e aplicações médicas do Machine Learning.




Fonte: Panesar,2020.

O ML pode ser dividido em dois ramos principais: Aprendizado Superficial ou “*Single*

or *Shallow Learning*” (única camada de neurônio artificial) e Aprendizado Profundo ou “*Deep Learning*” (múltiplas / ocultas camadas de neurônios artificiais), conforme podemos observar na Figura 6 (COHEN; NAHED; SHETH, 2013) (DUONG; RAUSCHECKER; MOHAN, 2020).

FIGURA 6 - Arquitetura básica do Aprendizado Superficial e Profundo de Máquinas.

“Shallow Learning”- Aprendizado Superficial- Camada Única x “Deep Learning”- Aprendizado Profundo- Múltiplas Camadas



Fonte: Autores.

O Aprendizado de Máquina também pode ser subdividido em Supervisionado e não Supervisionado, como exemplificado na Figura 7.

Nos modelos de Aprendizado de Máquina Supervisionados, os dados necessitam ser rotulados previamente por categorias (classificação) ou valores numéricos (regressão). Os modelos de classificação supervisionada têm geralmente uma única camada de neurônio artificial (*Single Layer*). Citamos como exemplos destes modelos a Regressão Logística, *Naive -Bayes*, Árvores de Decisão (*Decision Trees*), Florestas Aleatórias (*Random Forests*), *K - Nearest Neighbor* (KNN) e Máquinas de Vetores de Suporte Máquinas (SVM) (SHAVER et al., 2020) (VALLIANI; RANTI; OERMANN, 2019) (MCBEE et al., 2018).

Já os modelos de Aprendizado de Máquinas não Supervisionados visam identificar padrões em dados não rotulados, organizando os em conjuntos de dados complexos em grupos (*Clusters*) ou simplificando o número de variáveis (redução de dimensionalidade). Os modelos de classificação não supervisionados possuem múltiplas e escondidas camadas de neurônios artificiais (*Hidden Layers* ou *Deep Learning* – DL). São exemplos de DL as Redes Neurais Convolucionais (CNN) e as Redes Neurais Recorrentes (RNN) (JIANG et al., 2017) (ZAHARCHUK et al., 2018) (KAUL; ENSLIN; GROSS, 2020) (ZHU et al., 2019).

FIGURA 7 - Exemplos de Machine Learnings supervisionados e não supervisionados.



Fonte: Autores.

É crescente o estudo e emprego do DL dentro da medicina. Diferentemente dos modelos de ML supervisionados, as representações e /ou resultados são descobertos automaticamente a partir de dados brutos. Múltiplas e profundas camadas de classificadores capturam as representações de dados, tanto de baixo quanto de alto nível, permitindo que os *softwares* “aprendam” de forma mais rica abstrações de entradas (VALLIANI; RANTI; OERMANN, 2019) (MCBEE et al., 2018) (JIANG et al., 2017).

O DL elimina a necessidade para engenharia manual de recursos como dados pré-trabalhados, também chamados de dados “rasos”. Permite modelos de aprendizagem profunda para descobrir naturalmente padrões previamente desconhecidos e generalizar melhor para novos dados. Pode utilizar de grandes fontes de dados, ou *Big Data*, para encontrar padrões ou comportamentos nem sempre óbvios, que num contexto clínico podem ser de salutar interesse a reconhecimento. De forma sumária, podemos compreender que o *Deep Learning* é uma das modalidades de *Machine Learning*, que por sua vez é uma das áreas de pesquisa em Inteligência Artificial, como exemplificado na Figura 8 (PANESAR et al., 2020) (KAUL; ENSLIN; GROSS, 2020) (PESAPANE; CODARI; SARDANELLI, 2018) (OLTHOF; VAN OOIJEN; REZAZADE MEHRIZI, 2020).

FIGURA 8 - Inteligência artificial, ML e DL: sumário.



Fonte: Pesapane, 2018.

2.2 O MACHINE LEARNING NAS NEUROCIÊNCIAS MÉDICAS:

Vários pesquisadores médicos vêm tentando utilizar dessa capacidade de classificação e identificação de padrões em benefício de seus pacientes. Inúmeras especialidades médicas, mesmo fora do campo das neurociências clínicas, têm se beneficiado, sobretudo aquelas correlacionadas à prática diária de realização e interpretação de imagens (RAMESH et al., 2004).

Como exemplo, podemos citar a Ortopedia, onde o diagnóstico de lesões do sistema osteoarticular e muscular é grandemente dependente de recursos de imagens como TCs e RNMs, onde o uso da AI tem se mostrado comparável à expertise humana na identificação de fraturas, lateralidade de lesões e partes do corpo comprometidas (RICHARDSON et al., 2020) (GOLDBERG et al., 2020).

Em 2018, houveram mais de 6.000 publicações de trabalhos na base de dados *PUBMED* associando a IA, ML ou DL, à neuroradiologia, neurologia, neurooncologia ou neurocirurgia. Dentro da Neurologia e sua interface com a Neuroradiologia são inúmeras as frentes de trabalhos executadas usando ML e DL (DUONG; RAUSCHECKER; MOHAN, 2020).

No tratamento da Esclerose Múltipla o cruzamento de dados clínicos, radiológicos e laboratoriais sugerem ser úteis para diagnósticos duvidosos, caracterização de progressão da doença e decisões terapêuticas (DUONG; RAUSCHECKER; MOHAN, 2020).

Na abordagem das Epilepsias de Difícil Controle a análise sistemática dos perfis radiológicos, eletroencefalográficos e metabólicos cerebrais (SPECT / PET-CT) visam a

identificação de bons ou maus candidatos à cirurgia (PALDINO et al., 2017) (DUONG; RAUSCHECKER; MOHAN, 2020).

Na Demência de Alzheimer o emprego de dados clínicos, laboratoriais, genéticos e exames neuropsicológicos dão perspectiva quanto ao correto diagnóstico da enfermidade, frequentemente confundido com outros tipos de demências, colaborando quanto à predição de progressões aceleradas e escolhas de tratamentos (LI et al., 2019) (QIU et al., 2020) (ZHU et al., 2019).

A Neurocirurgia e suas interfaces com a Radiologia e a Oncologia muito se beneficiam do emprego da IA . Como exemplo da aplicação do ML e DL na Neurocirurgia, podemos citar o processamento conjunto de múltiplas fontes de dados como: exames de imagens, exames clínicos, laboratoriais e painéis genéticos tumorais, buscando-se determinar a melhor estratégia para tratamento a ser empregada, além de prever o tempo de sobrevivência de pacientes portadores de tumores cerebrais malignos (SHAVER et al., 2019) (LAO et al., 2017) (TITANO et al., 2018) (STOYANOV; DZHENKOV, 2018) (PARK; KICKINGEREDER; KIM, 2020).

Várias outras aplicações da IA vêm sendo estudadas na Neurocirurgia, como podemos exemplificar: a classificação de lesões de diagnóstico difícil, a definição de bordas tumorais, no planejamento pré-operatório de ressecções tumorais amplas ou múltiplas, no pós-operatório para se observar recidivas tumorais, no controle pós-radioterápico para exclusão de recidivas e na investigação de pseudoprogredões. Merece destaque a Radiogenômica, onde há a correlação de padrões de imagem com variantes genéticas tumorais, sendo utilizada para diagnósticos, terapias e prognósticos dos pacientes antes mesmo da coleta invasiva de amostras para estudos histopatológicos (SARKISS; GERMANO, 2019) (BUCHLAK et al., 2020) (VALLIANI et al., 2019) (DASGUPTA; GUPTA, 2019) (KAUSAR et al., 2011) (ZEINELDIN et al., 2020) (WINKLER-SCHWARTZ et al., 2019) (PEREZ-BREVA; SHIN, 2019).

Em especial na Neurotraumatologia, vários centros realizam trabalhos de classificação de imagens utilizando ferramentas de IA. Um estudo realizado no Reino Unido em 2020, utilizando imagens de 937 pacientes recrutados em mais de 60 centros clínicos europeus, construiu dois datasets de imagens de Tcs de crânio pós- TCEs, sendo 184 amostras para treinamento e 655 amostras para teste, submetendo-as à análise por Redes Convolucionais Neurais (CNN), um modelo de DL. Obteve-se sucesso, não apenas identificando a presença de sangramentos (HICs), bem como os segmentando em subtipos conforme localização (parenquimatosa, extradural, subdural) e determinando sua volumetria. Outro trabalho indiano de 2018, utilizando datasets com 313.318 TCs de crânio, também encontrou resultados satisfatórios. Propôs dentro de suas conclusões que tais algoritmos fossem utilizados como

método de triagem de HICs (MONTEIRO et al., 2020) (ANEJA; CHANG; OMURO, 2019) (CHILAMKURTHY et al., 2018) (CRUZ RIVERA et al., 2020).

2.3 SUS E OS TRAUMAS ENCEFÁLICOS NO INTERIOR

Este estudo idealizou um algoritmo de IA seguindo as características dos estudos anteriores, focando nos potenciais benefícios do seu emprego na saúde pública. O Brasil possui um dos maiores serviços de saúde pública do mundo, o SUS, abrangendo de forma universal sua população. Criado em 1988 com a promulgação da Constituição Federal, foi regulamentado pela lei nº 8.080/90. Tem como definição "o conjunto de ações e serviços de saúde, prestados por órgãos e instituições públicas federais, estaduais e municipais, da Administração direta e indireta e das fundações mantidas pelo Poder Público (BRASIL. MINISTÉRIO DA SAÚDE. SECRETARIA NACIONAL DE ASSISTÊNCIA À SAÚDE., 1990).

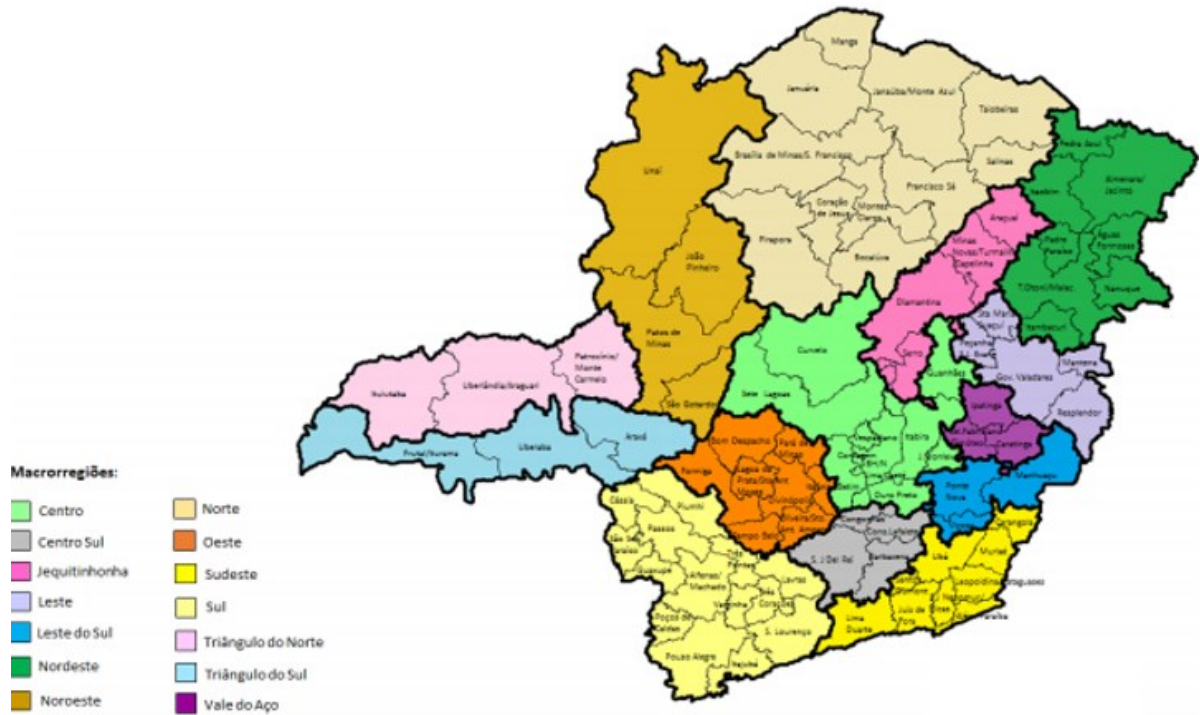
Suas principais premissas são a Universalidade, a Integralidade e a Equidade de atendimento à saúde dos brasileiros, assegurando-lhes os mesmos direitos e qualidades similares de atendimentos, sem distinção. Dentre seus pilares básicos encontram-se os princípios da Regionalização e Hierarquização dos serviços de saúde (PAIM, 2018).

Entende-se como Hierarquização os diferentes níveis de complexidade de atendimento à saúde que os municípios possuem. Existem centros de baixa, média e alta complexidade. Na sua lógica, quando um centro de baixa complexidade não possui condições de atenção a um paciente, ele é referenciado para um centro de maior complexidade, seja ele de média ou alta complexidade (MINISTÉRIO DA SAÚDE, 2016).

Por conta de suas dimensões continentais, o princípio de Regionalização levou a divisão dos municípios em macrorregiões onde poderiam ser encontrados no seu interior todos os três níveis de hierarquias (alta, média e baixa complexidade). Como exemplo, a Figura 9 mostra a divisão do Estado de Minas Gerais em Macrorregiões Assistenciais de Saúde (RODRIGUES et al., 2018).

Mesmo subdividido, as distâncias entre centros de baixa e alta complexidade ultrapassam centenas de quilômetros. Podemos citar a Macrorregião Noroeste / MG, com 33 municípios e uma de população com cerca de 793 mil habitantes. Como demonstrado na Figura 10, as transferências entre os municípios de Buritis (baixa complexidade) e Patos de Minas (única referência em Neurocirurgia na Macrorregião Noroeste e média complexidade), demoram, em média, 5 horas e 47 minutos por via terrestre (SRS PATOS DE MINAS _ SECRETARIA DE ESTADO DE SAÚDE DE MINAS GERAIS, [s.d.]).

FIGURA 9 - Macrorregiões de Saúde / MG.



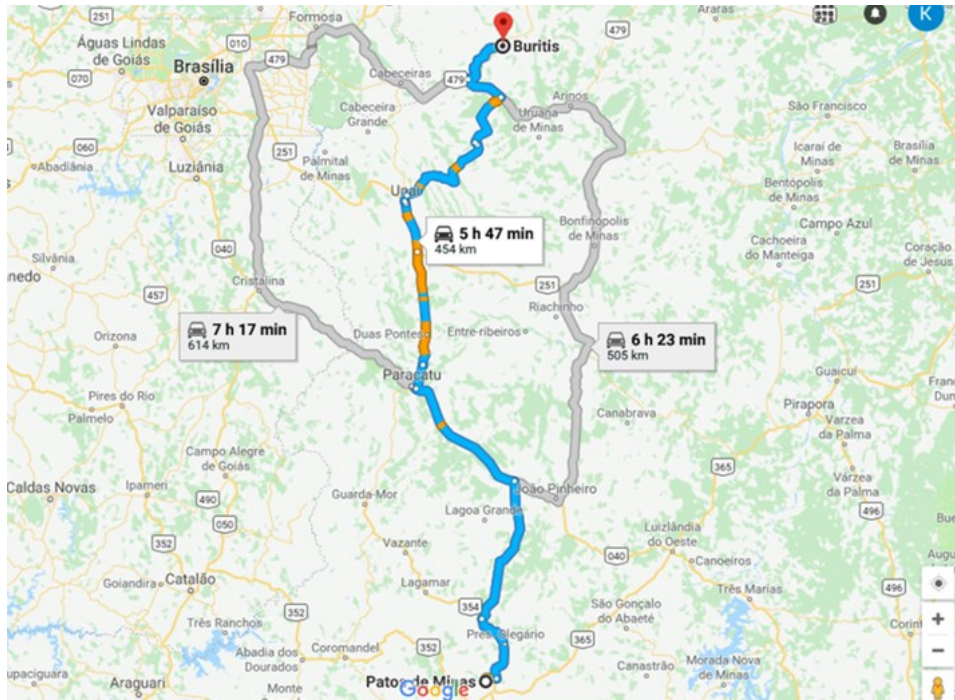
Fonte: site SES-MG, 2020.

O processo de transferência de um centro de menor complexidade para um de maior complexidade dentro de uma macrorregião é gerida por um sistema de regulação de vagas de leitos que no estado de Minas Gerais ganhou o nome de SUSFÁCIL. É uma plataforma on-line onde são digitados os dados dos enfermos para posterior análise por um médico na central macrorregional de regulação, que analisa as características do caso, verifica a existência de vaga em hospitais de maior complexidade hierárquica e intermedia a transferência do enfermo (SECRETARIA DE ESTADO DE SAÚDE DE MINAS GERAIS, 2005) (TORRES; BELISÁRIO; MELO, 2015) (CAMPOS, 2018) (MINISTÉRIO DA SAÚDE, 2016).

O processo necessita de dados digitados manualmente na plataforma para análise pelo médico regulador, tempo precioso, quando o intervalo entre o atendimento inicial e o tratamento definitivo é crucial para redução de sequelas e mortalidade. Problemas podem provocar atrasos no atendimento como a falta de vagas em centros de tratamentos intensivos, de profissionais especializados e longas distâncias percorridas para o referenciamento (BRUFFAERTS et al., 2017) (BANSAL et al., 2009)(SOP et al., 2013).

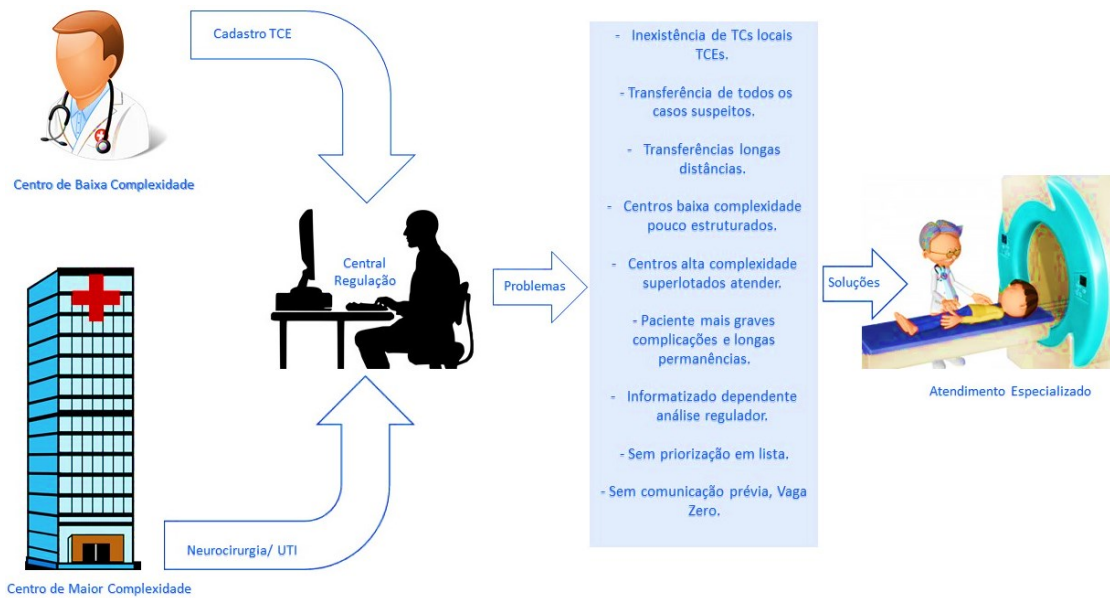
Na Figura 11 é sumarizado algumas dificuldades relacionadas ao processo de Regulação e Transferência de pacientes vítimas de TCEs observadas pelo autor, como referência única de Neurocirurgia da Macrorregião Noroeste de MG.

FIGURA 10 - Exemplo de longa distância de transferência.



Fonte: Google Maps, 2021.

FIGURA 11 - Racionalização do fluxo de regulação de leitos e alguns problemas.



Fonte: Autores.

Dentro da abordagem neurocirúrgica dos TCEs, o tempo é de suma importância. Quarenta e cinco por cento das vítimas de TCEs graves falecem na primeira hora seguinte ao trauma, devido a lesões com efeito de massa ou distúrbios cardiocirculatórios. Um segundo

pico, com 24% de óbitos, ocorre até a quarta hora do trauma, demonstrando que o acesso rápido à centros de tratamento com a disponibilidade de neurocirurgia é essencial para muitos enfermos. Atendimento ágil aos pacientes de TCEs é crucial para reduzir a morbimortalidade. É chamada de “Hora de Ouro” os primeiros 60 minutos seguintes ao trauma e os pacientes atendidos após esse período tem pior desfecho. Nos TCEs com Escala de Coma de Glasgow < 4, a mortalidade é de até 53% nos 6 meses seguintes ao acidente. Diagnósticos retardados, longas distâncias e dificuldades de transferências podem ter grande impacto no desfecho dos casos de TCEs conforme dados acima mencionados (BRUFFAERTS et al, 2017) (BANSAL et al., 2009) (CARNEY et al., 2017).

2.4 INTELIGÊNCIA ARTIFICIAL E SUS FÁCIL

Poderíamos enumerar vários potenciais benefícios do desenvolvimento e utilização de ferramentas computacionais e de IA para detecção de HICs através de imagens de TCs nas cidades do interior, distantes dos grandes centros médicos (GOLDBERG et al., 2020).

Seu emprego alertaria os profissionais médicos e técnicos locais de condições potencialmente fatais, acelerando a tomada de providências quanto ao tratamento adequado, como cadastros, contatos telefônicos ou por aplicativos, com as Centrais de Regulação de Leitos e hospitais de maior complexidade (RICHARDSON et al., 2020).

Poderiam ser úteis como ferramenta de priorização de lista, permitindo análise ágil dos pacientes dentro da plataforma de regulação de leito SUS FÁCIL, inclusive com a possibilidade de inclusão futura de ferramentas de segmentação e volumetria de HICs, dados importantes quanto à decisões da necessidade ou não de intervenções neurocirúrgicas emergenciais (RICHARDSON et al., 2020).

Poderiam ser uma conexão à sistemas integrados de Telemedicina, onde agilizariam pareceres de médicos especialistas nos centros de maior complexidade ou nas Centrais de Regulação do SUS FÁCIL, em auxílio aos profissionais locais na condução de casos graves ou complexos (CAMPOS et al., 2020).

Forneceriam sistemas automatizados de alertas remotos de neurocirurgiões nos centros de maior complexidade da ocorrência à distância de um TCE grave, antecipando assim cadastros e o preparo cirúrgico na instituição de destino para as necessidades terapêuticas antes de concluída a transferência do enfermo, como por exemplo: reservas de leitos de terapia intensiva, reservas de hemoderivados, pré-cálculo de doses de medicações anestésicas, reserva de salas cirúrgicas, dentre outros (CARNEY et al., 2017) (PANESAR et al., 2020).

Reduziria o tempo de transferências para locais onde existam recursos disponíveis, evitaria deslocamentos desnecessários para a realização de TCs diagnósticas em centros de média e alta complexidade, aliviando-os de superlotação de suas emergências (AZEVEDO et al., 2016).

Como supracitado sobre a escassez de grandes estudos epidemiológicos nacionais, a integração de uma ferramenta de detecção de HICs num sistema estadual de regulação, proporcionaria valiosa coleta de dados para a elaboração de estudos de larga escala, pois permite conectividade de múltiplos centros a plataforma única de dados (RICHARDSON et al., 2020).

A grande quantidade e qualidade de dados gerados após análise por IA dos casos de TCEs, viabilizariam aos gestores de saúde de várias esferas, novas informações quanto às necessidades de recursos financeiros, aquisições de insumos, contratações de pessoal ou pactuações de serviços (BRASIL. MINISTÉRIO DA SAÚDE. SECRETARIA NACIONAL DE ASSISTÊNCIA À SAÚDE., 1990).

Geraria economia aos cofres públicos, pois reduziria os custos globais de internações (diárias, insumos, pessoal), pois melhorando a assistência aos pacientes com TCEs. Diagnósticos precoces e rápidos tratamentos determinariam menor potencial de complicações e hospitalizações prolongadas. Economias estas que poderiam ser revertidas na aquisição de novos aparelhos de TCs para localidades sem tal recurso e em pesquisa para o desenvolvimento e emprego de IA para a saúde (CDC; NCIPC, 2015).

A detecção automatizada de HICs, aliada a informação de elementos terapêuticos essenciais em neurotraumatologia como sua localização, volume e efeito compressivo encefálico, poderiam ser utilizados para o desenvolvimento de aplicativos ou programas contendo algoritmos de manejo clínico (MONTEIRO et al., 2020).

Poderiam ser utilizadas plataformas digitais economicamente acessíveis conectadas à internet tais como notebooks, desktops e smartphones como auxiliares na formulação de estratégias terapêuticas destes enfermos. Ao abrir um aplicativo um neurocirurgião de uma capital poderia auxiliar ou mesmo dar a autorização de transferência de um enfermo de uma cidade do interior no tempo de um arraste de dedo indicador (SANOSSIAN et al., 2009).

Através de preenchimento de formulários *on-line* num futuro adicionados à ferramenta proposta, gerariam dados que alimentariam data sets com importantes informações sobre a história clínica, exame físico e propedêutica adjuvante (exames radiográficos, eletrocardiográficos, laboratoriais, dentre outros) dos pacientes vítimas de TCEs. Tais informações poderiam traçar sugestões de algoritmos terapêuticos com recursos localmente

disponíveis. Caso os recursos terapêuticos não existirem naquele centro, sugeririam aos gestores locais as adequações necessárias para a manutenção da vida e a redução de potenciais sequelas, como por exemplo ampliação de salas de emergências e aquisição de serviços de terapia intensiva. (DUONG; RAUSCHECKER; MOHAN, 2020) (HALE et al., 2019).

Uma ferramenta de IA também poderia corroborar na própria prevenção de TCEs. Por exemplo, a alimentação do sistema com dados como locais de acidentes e seus mecanismos como: trechos de rodovias com altos índices de acidentes, locais com elevados índices de infrações de trânsito, tais como: avanços de esquinas, paradas obrigatórias, semáforos, o não uso de capacetes, dentre outros. Informações que num mundo interconectado, não são mais ficção científica (DAPP; HEINE, 2012).

3 ARTIGO

**DESENVOLVIMENTO DE ALGORITMO DE INTELIGÊNCIA
ARTIFICIAL PARA DETECÇÃO DE HEMORRAGIAS
INTRACRANIANAS PÓS-TRAUMATISMOS ENCEFÁLICOS:
POTENCIAIS BENEFÍCIOS DE SUA INCORPORAÇÃO NA
PLATAFORMA *SUS FÁCIL*.**

DEVELOPMENT OF AN ARTIFICIAL INTELLIGENCE ALGORITHM FOR THE
DETECTION OF INTRACRANIAL HEMORRHAGES AFTER TRAUMATIC BRAIN
INJURIES: POTENTIAL BENEFITS OF ITS INCORPORATION INTO THE *SUS FÁCIL*
PLATFORM.

CAIXETA, Talles Henrique^{1 2}; OLIVEIRA, Vítor Nunes³; AMARAL, Laurence Rodrigues⁴.

¹Aluno do Programa de Pós-Graduação em Biotecnologia (PPGBIOTEC) da Universidade Federal de Uberlândia (UFU)– Campus Patos de Minas-MG. tallescaixeta@ufu.br

²Neurocirurgião dos Hospitais Imaculada Conceição e Vera Cruz, Patos de Minas -MG.

³ Graduação do PPGBIOTEC, UFU, Campus Patos de Minas -MG. vitorn.oliveira@hotmail.com.

⁴Professor Doutor, Coordenador do PPGBIOTEC, UFU, Campus Patos de Minas -MG. laurence@ufu.br

Endereço: Rua Cônego Getúlio, 315. Ed. Atlanta. Centro. Patos de Minas, Minas Gerais. Brasil. CEP: 38700-150.

E-mail: tallescaixeta@gmail.com.

RESUMO

O estudo e utilização da Inteligência Artificial (IA) na medicina têm crescimento exponencial. Ferramentas auxiliares à identificação de ameaças à vida e de priorização de casos poderiam ser benéficas na condução de Traumas Cranioencefálicos (TCEs) no âmbito do Sistema Único de Saúde (SUS). Estes são problemas de saúde pública, resultam em Hemorragias Intracranianas (HICs) de elevada morbimortalidade e custos socioeconômicos, sobretudo quando não tratadas em tempo hábil. Em Minas Gerais, quando incidem em municípios de baixa complexidade hospitalar, sem neurocirurgiões, radiologistas ou tomografias computadorizadas (TCs), necessitam por mecanismo de hierarquização transferir seus pacientes usando-se a plataforma de regulação de leitos SUS FÁCIL (SF). Retardos na identificação e cadastros dos casos graves na origem, da sua análise por médicos reguladores do SF, poderiam ser amenizados com a inserção na plataforma de um algoritmo de IA capaz de reconhecer automaticamente HICs em TCs nos locais de origem, agilizando a detecção e priorização de casos ameaçadores a vida. Este trabalho propõe o desenvolvimento de um algoritmo para identificação de HICs em TCs e a análise dos seus potenciais benefícios no contexto do SF. Após a coleta, processamento e formulação de datasets de imagens de TCs de crânio normais e com HICs, utilizou-se o *software* Orange® para treinamento, validação e teste do seu reconhecimento por modelos de Redes Neurais Artificiais (ANN), Máquinas de Vetores de Suporte (SVM), Florestas Aleatórias (*Random Forests*) e *K – Nearest- Neighbors* (KNN) . O modelo de ANN apresentou resultados ligeiramente superiores aos demais modelos nas etapas de Treinamento / Validação e Teste (AUC = 1.000, CA = 0.998, F1 = 0.998, Precisão = 0.998 e Recall = 0.998, e AUC = 0.987, CA= 0.930, F1= 0.930, Precision = 0.931 e Recall = 0.930 respectivamente) conseguindo atingir o objetivo proposto para o conjunto de imagens utilizadas. A formulação de datasets mais robustos tornam-se necessários para seu uso prático e o aperfeiçoamento e emprego de algoritmos de IA devem ser incentivados.

ABSTRACT

The study and use of Artificial Intelligence (AI) in medicine has grown exponentially. Auxiliary tools for identifying potential threats to life and prioritizing cases could be beneficial in the management of Traumatic Brain Injuries (TBIs) within the scope of the Unified Health System (SUS). These are public health problems, often resulting in Intracranial Hemorrhages (ICH) with high morbidity and mortality and socioeconomic costs, especially when not treated in a timely manner. In Minas Gerais, when they focus on cities with low hospital complexity, without neurosurgeons, radiologists, or computed tomography (CTs), they need to transfer their patients, using the SUS FÁCIL bed regulation platform, through a hierarchical mechanism. The delay in the identification and registration of serious cases at the origin, their analysis by regulators in the SF regulation centers, could be alleviated with the potential insertion of an AI algorithm capable of automatically recognizing HICs in CTs at the origin sites, thus adding agility for the detection and prioritization of life-threatening cases. This work proposes the development of an ICH identification algorithm in CT and the analysis of its potential benefits in the context of SUS FÁCIL. After collecting and processing data sets images containing normal and HIC skull CTs, Orange® Software was used for training, validation and testing of their recognition by Artificial Neural Network (ANN) models, Support Vector Machines (SVM), Random Forests and K – Nearest-Neighbors (KNN). The ANN model presented slightly better results than the other models in the Training / Validation and Testing stages (AUC = 1,000, CA = 0.998, F1 = 0.998, Accuracy = 0.998 and Recall = 0.998, and AUC = 0.987, CA = 0.930, F1 = 0.930, Precision = 0.931 and Recall = 0.930 respectively) achieving the proposed objective for the set of images used. However, the formulation of more robust datasets becomes necessary for their practical use and their improvement and use should be encouraged.

Palavras-chave: Inteligência Artificial, Trauma Cranioencefálico, Hemorragia Intracraniana, Aprendizado de Máquina, Sistema Único Saúde, SUS FÁCIL.

Keywords: Artificial Intelligence, Brain Trauma Injury, Intracranial Hemorrhages, Machine Learning, Unified Health System, SUS FÁCIL.

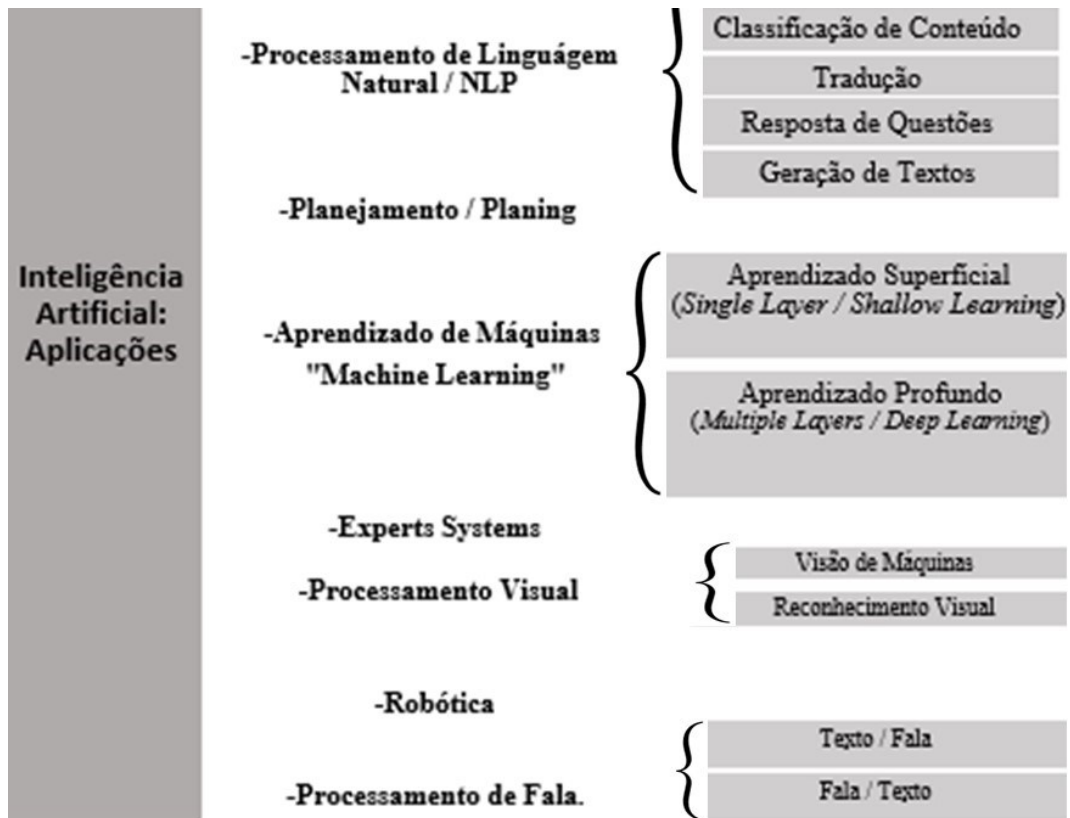
3.1 INTRODUÇÃO

Inteligência Artificial (IA) pode ser definida como a capacidade de uma máquina, geralmente um computador, se portar de forma semelhante ao que antes se pensava ser exclusiva da inteligência humana. Por mecanismos de adaptação flexível, elas conseguem interpretar dados externos, aprender modelos e utilizar-se desses aprendizados para efetuarem tarefas específicas (1) (2).

A IA pode ser subdividida em vários campos de pesquisa, como o Aprendizado de Máquinas (*Machine Learning*) que realiza previsões por reconhecimento de padrões de dados ou o Processamento de Linguagem Natural (*Natural Language Processing*), capaz de produzir previsões por intermédio de análise de dados de textos, conforme exemplificado na Figura 1 (3) (4).

O estudo da Inteligência Artificial (IA) remonta 1956 quando os cientistas de computação *John McCarthy* e *Marvin Minsky* organizaram o *Dartmouth Summer Research Project on Artificial Intelligence*, evento aonde o termo IA foi primeiramente citado. Nos anos 1960 houve certo desinteresse dos pesquisadores médicos pela IA, ressurgindo sua pesquisa na década seguinte com a criação do *Research Resource on Computers in Biomedicine* da Universidade Rutgers. Durante o Congresso da Academia Americana de Oftalmologia de 1976, esta iniciativa científica apresentou para a comunidade médica o *CASNET®*, primeiro protótipo de aplicativo que utiliza da IA para auxílio ao manejo do Glaucoma. Em 1993, surgem as primeiras publicações por radiologistas estudando a IA na detecção de neoplasias malignas em mamografias, denotando a abertura de uma era de crescente interesse da Radiologia pelo uso da IA (5) (6) (7).

FIGURA 1 - Os vários tipos de Inteligências Artificiais e a subdivisão do Machine Learning.

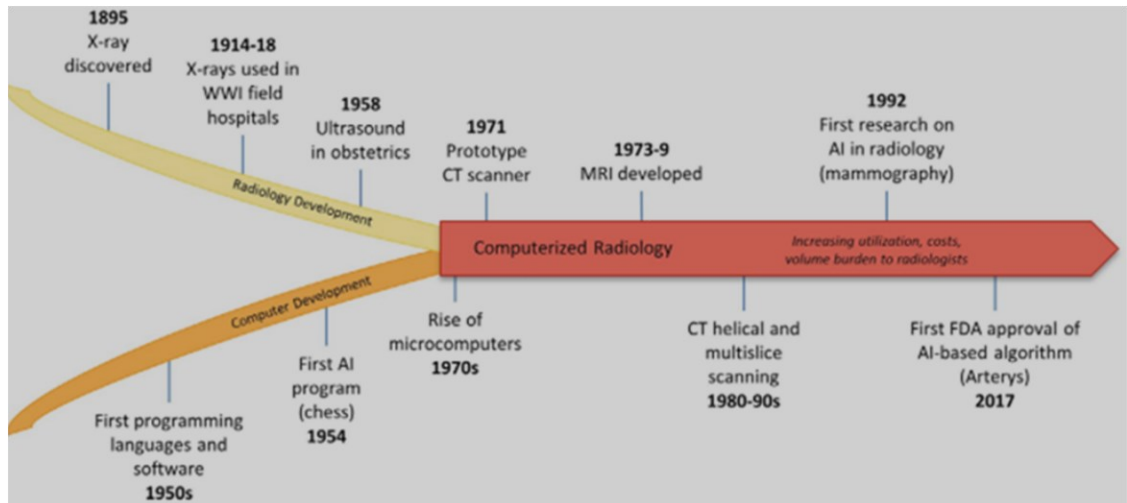


Fonte: Panesar, 2020.

Desde os anos 1970, quando surgiram os protótipos das Tomografias Computadorizadas (TCs), das Ressonâncias Nucleares Magnéticas (RNMs) e dos Computadores Pessoais (PCs), até chegarmos aos dias atuais houve crescente interesse em pesquisas sobre IA principalmente na Neuroradiologia. Ao longo do tempo houve um paralelo entre as crescentes melhorias dos recursos computacionais e o advento dos exames de imagens, conforme mostrado na Figura 2 (8).

A abundância de recursos de imagem, de tecnologia computacional acessível e de troca de informações pela Internet, levou nos últimos cinco anos a um aumento significativo de trabalhos publicados em periódicos médicos utilizando-se de pesquisas em IA, sobretudo na neuroradiologia. A Figura 3 ilustra este crescimento (9).

FIGURA 2 - Paralelo histórico entre IA e desenvolvimento da Radiologia.




Fonte: Kaul, 2020.

A IA pode ser uma ferramenta útil na rápida detecção de padrões de imagem de patologias ameaçadoras a vida, como por exemplo, as Hemorragias Intracranianas (HICs) secundárias a Traumatismos Cranioencefálicos (TCEs). Em emergências a rápida detecção de HICs é crucial em virtude do potencial de danos neurológicos severos e óbitos relacionados a sua patologia (10) (11) (12).

Os TCEs são patologias de ocorrência comum em nosso meio, entretanto são escassos grandes estudos epidemiológicos brasileiros. Geralmente são estudos relacionados a centros hospitalares específicos, cidades e regiões, não sendo portanto de amplitude nacional (13) (14) (15).

Estatísticas americanas no ano de 2010, estimaram a avaliação de cerca de 2,5 milhões de vítimas de TCEs, sendo estes responsáveis por cerca de 15% de todos os atendimentos em serviços de emergência, seja como diagnóstico primário ou secundário. Destes 20% eram casos moderados ou graves, exigindo sua internação entre 50 a 70% das ocasiões (16) (17).

FIGURA 3 - Crescimento das publicações médicas em IA.



Fonte DUONG; RAUSCHECKER; MOHAN, 2020.

A mortalidade global dos TCEs foi estimada em cerca de 18/100.000 casos por ano. Acometem todas as faixas etárias, havendo predomínio no gênero masculino e em jovens. Houve crescimento de 62 % na incidência casos de TCEs em jovens americanos abaixo de 19 anos de idade entre os anos de 2001 e 2009, principalmente associados a práticas desportivas e recreação, denotando um problema em expansão. Os TCEs possuem altas taxas de mortalidade quando acometem idosos com mais de 75 anos. Ocorrem tanto em desenvolvidas capitais, com centros médicos de alta complexidade, quanto em pequenas cidades, sem qualquer infraestrutura especializada. Causam grande sofrimento para as vítimas e seus familiares, possuindo elevado custo socioeconômico, estima-se um gasto de cerca de 82 bilhões de dólares anuais com o seu tratamento (18) (19).

Tecnologias como as Tomografias Computadorizadas (TCs) foram essenciais para a compreensão da fisiopatologia, facilitando diagnósticos, otimizando tratamentos e melhorando prognósticos (10).

Contudo existem fatores limitantes para sua aplicação em larga escala em nosso meio. Seu emprego em municípios pequenos, dotados de orçamentos modestos, é dificultado pelo alto custo de aquisição de aparelhos. Também são limitadores a manutenção onerosa, a contratação de profissionais técnicos e médicos especializados como radiologistas, neurocirurgiões e intensivistas, além da burocracia na sua compra e manutenção (20).

A aquisição e manutenção isolada de TCs para a detecção precoce destas patologias seria uma opção economicamente viável para alguns destes municípios, todavia os elevados custos com quadro pessoal não seriam compatíveis com as suas realidades orçamentárias (21).

Tendo em mãos um real problema de saúde pública, aliada à escassez de meios para o seu tratamento, teríamos disponíveis alternativas tecnológicas viáveis capazes de reduzir o impacto dos TCEs sobre a sociedade tendo em vista o cenário assistencial do SUS atual? O atendimento especializado aos TCEs e a pronta identificação de HICs seriam factíveis à distância por intermédio de soluções tecnológicas como a IA e a Telemedicina, não obstante a realidade atual de inexistência de TCs nos locais de ocorrência dos acidentes (22) (23).

Este fato leva à invariável necessidade de transferência de todos os casos suspeitos, por vezes desnecessariamente centenas de quilômetros. Pacientes diagnosticados como TCEs de menor gravidade, poderiam hipoteticamente serem tratados localmente caso houvesse disponibilidade de TCs e consultoria especializada à distância. Por outro lado, as cidades detentoras de hospitais de média e alta complexidade, geralmente detêm salas de emergência e observações superlotadas, pois absorvem tanto os casos graves, quanto àqueles que a insuficiência de meios diagnósticos do interior os leva a atender (24) (25).

Questiona-se se a aplicação de soluções tecnológicas, como algoritmos de Aprendizado de Máquinas capazes de identificar HICs em TCs, poderiam reduzir o impacto dos TCEs sobre a sociedade, sobretudo quando aplicadas em um cenário de escassez de recursos assistenciais, como cidades com infraestrutura hospital de baixa complexidade. Esta pesquisa visa estudar, desenvolver e empregar um algoritmo de IA capaz de diferenciar imagens de TCs de crânio portadoras de HICs de controles normais e analisar seus potenciais benefícios no cenário assistencial do SUS.

3.2 MATERIAIS E MÉTODOS

Após aprovação pelos Comitês de Ética e Pesquisa (CEPs) das instituições parceiras, foram escolhidas para estudo imagens de TCs de crânio sem contraste de vítimas de TCEs atendidas nas emergências dos Hospitais Imaculada Conceição e Vera Cruz – Patos de Minas / Minas Gerais, no período anterior ao ano de 2018. Declaramos não haver conflitos de interesses, sendo o trabalho financiado pelos autores.

Utilizados dois tomógrafos *Phillips Brilliance*® de 16 e 64 canais. Nesta análise incluem-se exclusivamente imagens de TCs de crânio com achados de HICs e normais, selecionadas com base em laudos oficiais, realizadas por radiologistas colaboradores.

Os dados para a elaboração dos datasets usados neste trabalho foram coletados de duas fontes distintas. A primeira fonte foi a comunidade *on-line* para pesquisas *Kaggle*®, uma subsidiária da *Google*®, que provê aos seus usuários datasets para estudos relacionados ao Aprendizado de Máquina (*Machine Learning*). Foi feito o *download* do dataset aberto *RSNA Intracranial Hemorrhage Detection*, organizado pela Sociedade Americana de Neuroradiologia (ASNR), em colaboração com várias instituições de pesquisa. A segunda fonte para datasets foram as plataformas de imagens e laudos *Synapse*® e *Arya*® / *PACS*® (*Picture Archiving and Communication System*) pertencentes às instituições hospitalares parceiras (26) (12).

Originalmente os dados se encontravam em formato *DICOM.3*® (*Digital Imaging and Communications in Medicine*) e foram convertidos para o formato JPEG (*Joint Photographic Experts Group*). Após a conversão foram uniformizados e anonimizados na própria workstation do serviço e transferidos por *hard disk* externo para computadores pertencentes ao Laboratório de Bioinformática e Análises Moleculares (*LBAM*) da Universidade Federal de Uberlândia (UFU) – Campus Patos de Minas / MG.

Foram excluídas TCs de controles clínicos ou pós-operatórios. Não foram avaliados dados pessoais dos pacientes, portanto sem diferenciação quanto ao gênero, idade ou etnia, apenas empregados dados computacionais anônimos brutos. Não foram usadas imagens de menores de dezoito anos. Excluídas grandes lesões traumáticas de face como fraturas, lacerações ou hematomas, artefatos de movimento, corpos estranhos e achados patológicos intracranianos incidentais. Definiu-se como achados incidentais intracranianos: calcificações patológicas, doenças cerebrovasculares agudas e crônicas, malformações vasculares (p.ex. aneurismas), tumores benignos ou malignos, hemorragias cerebrais espontâneas, corpos estranhos, cliques de aneurismas, derivações ventriculares, dentre outras.

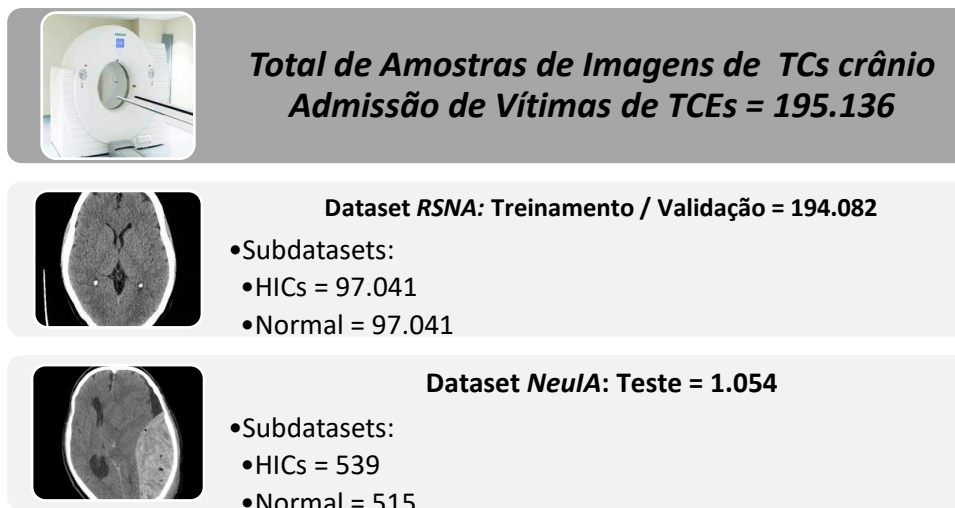
Requisitos de segurança como anonimização das imagens, acessos individuais com senhas, criptografias, softwares antivírus atualizados e checklist para estudos em imagem usando IA, foram respeitados conforme a Lei Geral de Proteção de Dados Pessoais (LGPD) e os Consensos *SPIRIT-AI*, *CONSORT-AI* e *CLAIM* (Anexo2). Os datasets ficaram sob guarda do LBAM e poderão ser utilizados para pesquisas futuras com autorizações das comissões de éticas pertinentes (27) (28) (29) (30) (31) (32).

Ao todo foram empregadas 195.136 imagens de TCs de crânio para este estudo. Destas, 194.082 imagens eram pertencentes ao dataset *RSNA* e 1054 imagens pertencentes ao dataset construído pelos autores (dataset *NeuIA*), baseado em casos neurocirúrgicos locais. O primeiro foi utilizado para treinamento e validação do algoritmo proposto e o segundo foi usado para testá-lo.

Foram selecionadas imagens com graus variáveis de dificuldade para a construção do dataset *NeuIA*, usando imagens contendo desde discretos achados de Hemorragias Subaracnóideas Traumáticas à grandes Hematomas Intracranianos Epidurais e Subdurais. Selecionou-se pacientes com faixa etária entre de 18 a 90 anos.

Para a etapa Treinamento e Validação do algoritmo as imagens obtidas *on-line* encontravam-se divididas em dois subdatasets: Pasta 0 / Subdataset HICs (50% do total, 97.041 imagens com HICs) e Pasta 1 / Subdataset Normal (50% do total, 97.041 imagens normais). O *Dataset NeuIA* também era composto por dois subdatasets: Subdataset *NeuIA* Normal (51%, 515 imagens normais) e Subdataset *NeuIA* HICs (49%, 539 imagens com HICs), conforme podemos observar na Figura 4.

FIGURA 4 - Origem e Notação dos Datasets.

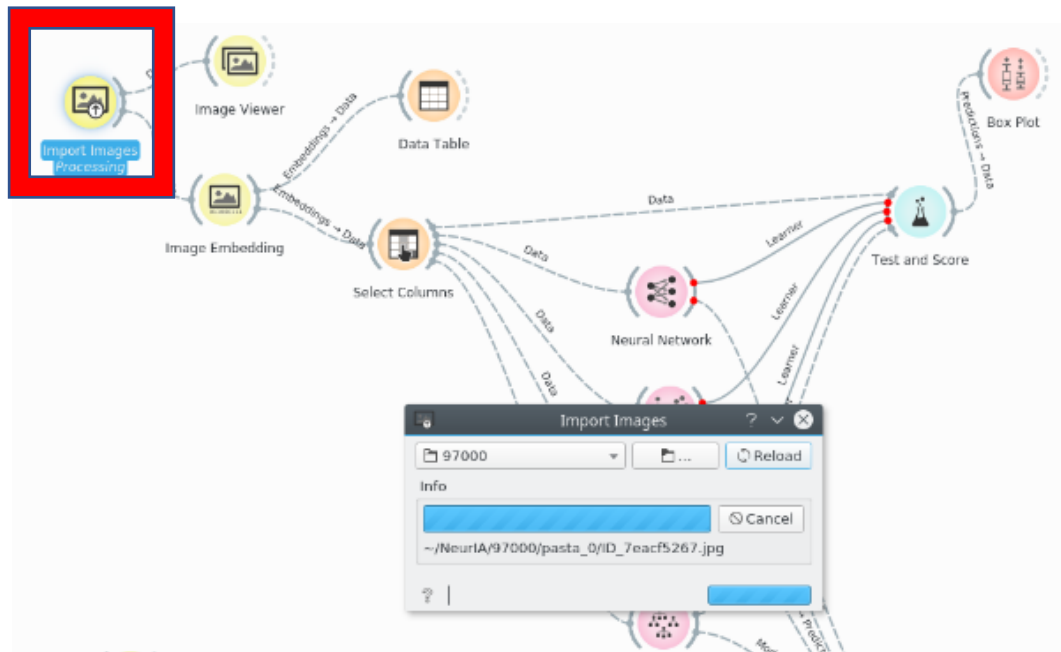


Fonte: Autores.

Para o processamento foi usado o software Orange®, que dispensou a digitação de códigos de comando em linguagem *Python*® para o algoritmo proposto. O programa possui interface simples, contendo ícones de programação rápida, detendo ferramentas de visualização e manipulação de dados que facilitaram a Mineração de Dados (*Data Mining*) e o manuseio de modelos de Aprendizado de máquina (*Machine Learning*) necessários para a pesquisa.

Usando o atalho, ou *widget*, da função Importar Imagens (*Import Images*), foi feito o carregamento, ou *download*, do Dataset *RNSA* para a etapa de Treinamento e Validação (Subdatasets HICs e Normal) para o ambiente Orange on-line, conforme mostrado na Figura 5.

FIGURA 5 - Fluxo do processamento de dados no algoritmo: Importação Imagens.



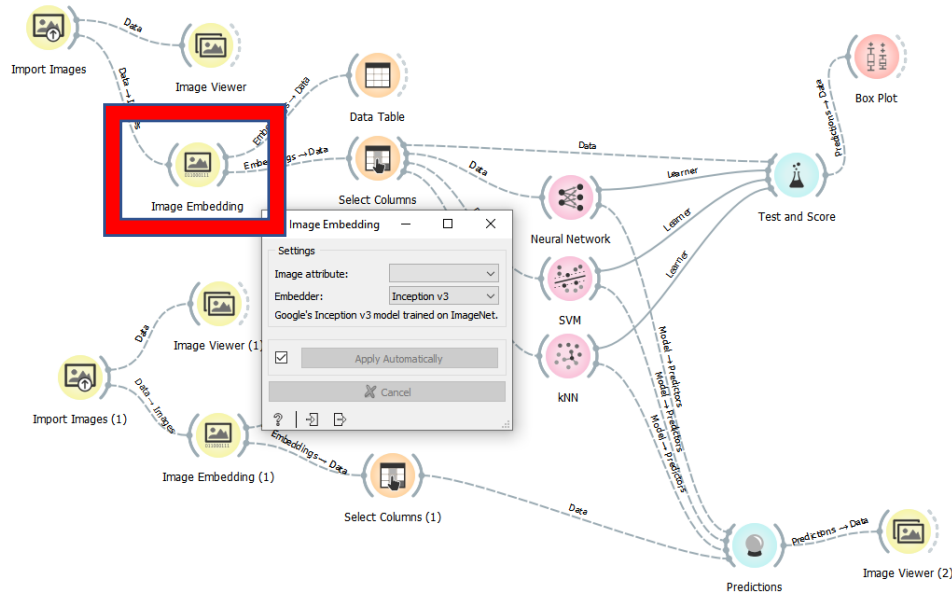
Fonte: Autores.

Estes são os dados de entrada (*inputs*) para processamento na etapa subsequente a função Incorporação de Imagens (*Image Embedding*). Nela as imagens são enviadas a servidores e processadas por modelos de *DL* que transformam as imagens (*inputs*) em representações numerais ou vetoriais (*outputs*). Estes modelos de Incorporação de Imagens são hospedados em servidores remotos (*on-line*) ou locais (*off-line*).

A função Incorporação de Imagens oferece vários tipos de Incorporadores (Embedders), que são diferentes modelos arquiteturais de Redes Neurais Convolucionais (CNN) / *Deep Learning*, utilizados para a intercambialidade de análises e regulação do algoritmo. São exemplos de Incorporadores o *Inception V3* e o *Inception V4* (remotos) e o *SqueezeNet* (local).

Utilizamos o *Inception V3* voltado à classificação de imagens e detecção de objetos, conforme mostrado na Figura 6.

FIGURA 6 - Fluxo do processamento de dados no algoritmo: Incorporação de Imagens.



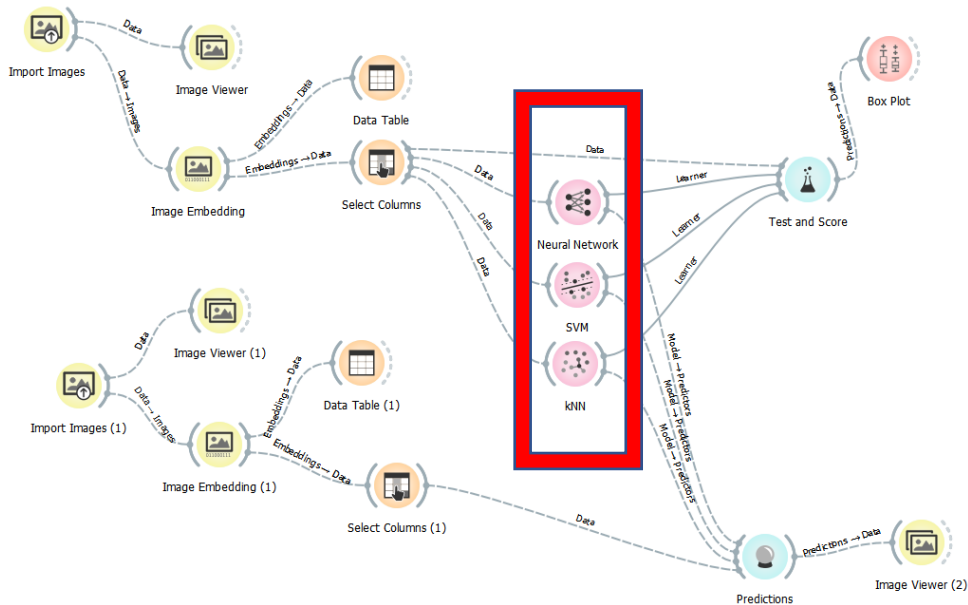
Fonte: Autores.

Estes dados vetorizados e tabelados são os dados de entrada (*inputs*) do seguinte passo nomeado Seleção de Colunas (*Select Columns*). Nela foram selecionados manualmente o domínio de dados a serem estudados, os atributos. Existem vários tipos de atributos: simples, de classe e meta atributos. Optou-se pela seleção de atributos simples e de classe discretos, adequados a tarefa de classificação de imagens.

Os atributos selecionados foram enviados como dados de entrada (*inputs*) para análise e comparação de resultados por quatro modelos classificadores de *Machine Learning* (mais simples, supervisionados e de menor custo operacional): *Artificial Neural Network* ou

Feedforward Neural Network (*ANN*), *k*-Nearest-Neighbours (*k*-*NN*), *Random Forests* e *Support Vector Machine (SVM)*, mostrados na Figura 7:

FIGURA 7 - Fluxo do processamento de dados no algoritmo: Modelos de Machine Learning.

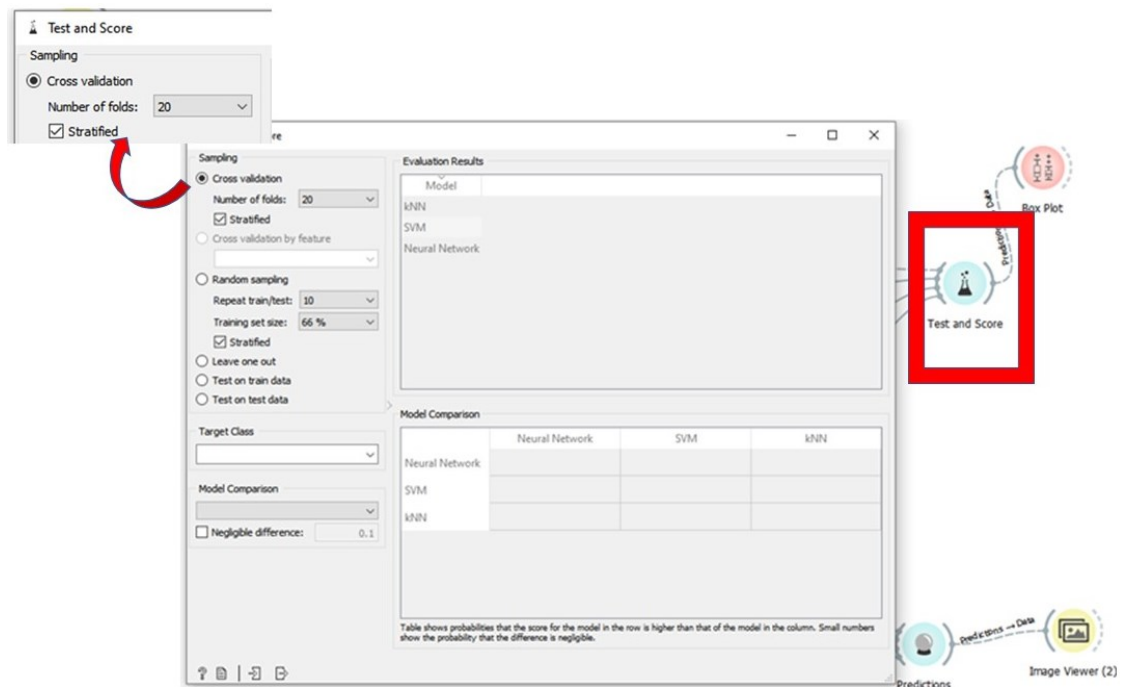


Fonte: Autores.

Os *outputs* destes modelos foram analisados separadamente no passo seguinte chamado “*Test and Score Running*”. Nela é mostrada os diferentes desempenhos dos modelos classificadores utilizados durante o treinamento, medindo-se sua performance estatística com as seguintes métricas: Área Sob a Curva ROC, Acurácia, *F1*, *Recall*, Precisão, *LogLoss* e Sensibilidade, métricas exemplificadas no Anexo 3.

O método de *Cross Validation*, divide os dados dos datasets de Treinamento HIC e Normal em subdatasets, comparando-os entre si, sendo usado para a Validação da classificação. Foi utilizada o *Cross Validation* de 10 *Folds* (dobras), onde os datasets treinados foram divididos em 10 grupos e cada subgrupo comparado entre si, como observado na Figura 8.

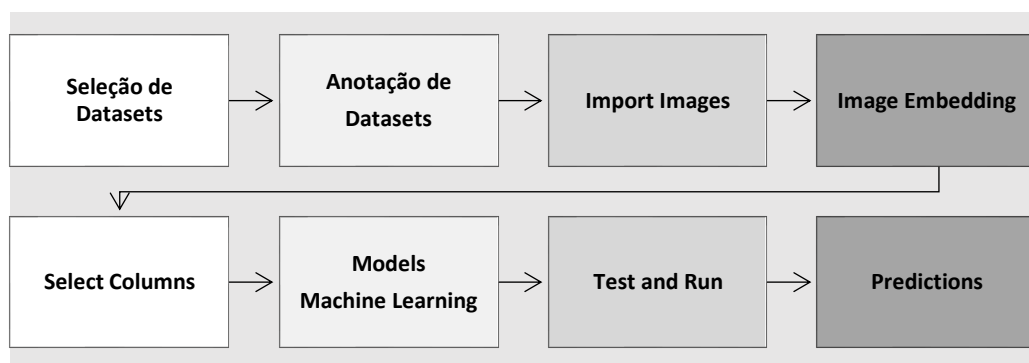
FIGURA 8 - Fluxo do processamento de dados no algoritmo: Test and Score.



Fonte: Autores.

Após a etapa de Treinamento e Validação, procedeu-se a etapa de Teste. Foi usado o dataset *NeuIA*, cujas imagens eram inéditas aos modelos classificadores treinados, a fim de se averiguar a performance estatística da análise frente a uma tarefa classificatória nova e com dados locais. Sumarizamos na Figura 9 as várias etapas supracitadas.

FIGURA 9 - Etapas de processamento de dados pelo algoritmo proposto.

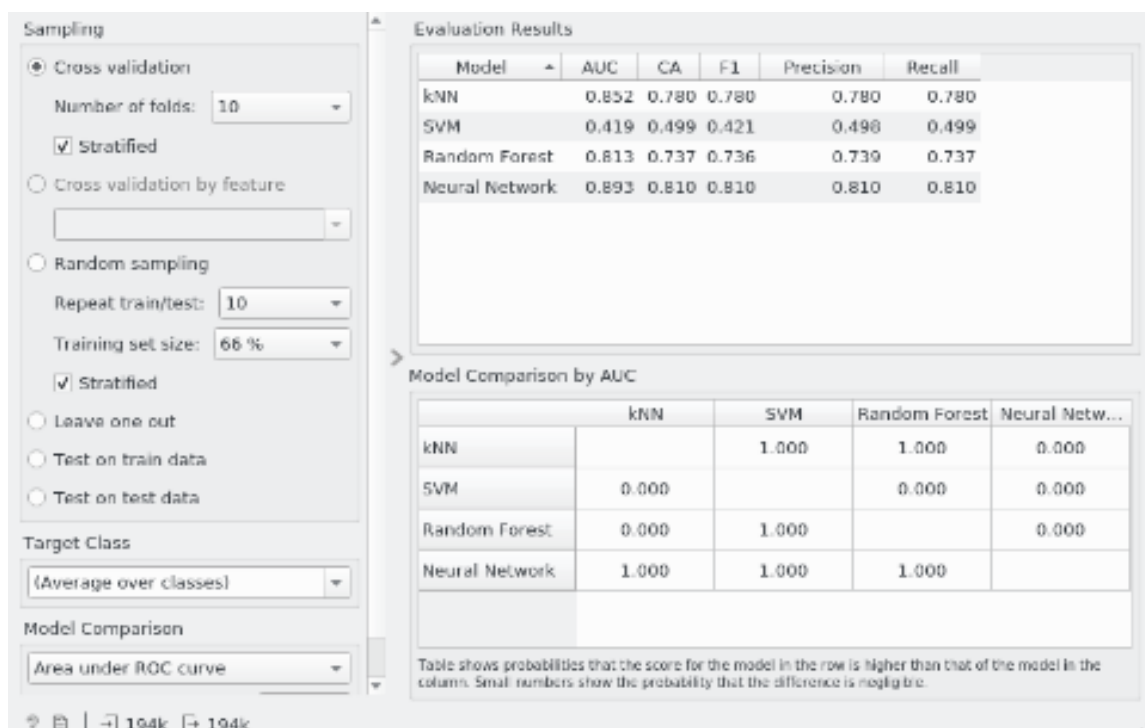


Fonte: Autores.

3.3 RESULTADOS

Após o processamento pelo algoritmo das imagens do dataset RSNA (194.082 imagens) na etapa de Treinamento e Validação, foram obtidos índices de classificação satisfatórios em três modelos de Machine Learning empregados, sumarizados no *widget* “Test e Score Running” do programa Orange® e mostrados na Figura 10.

FIGURA 10 - Resultados obtidos na etapa Treinamento e Validação.



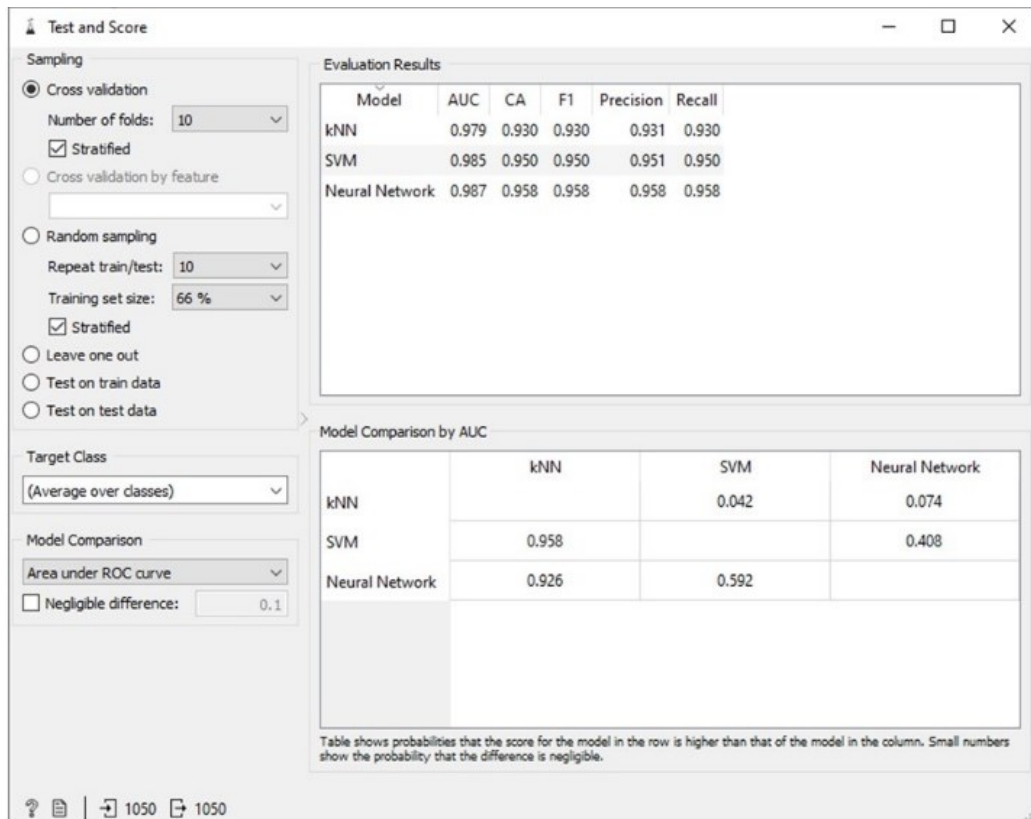
Fonte: Autores.

O modelo *Artificial Neural Networks (ANN)*, com maior poder computacional de processamento, utilizando a *Cross Validation* de 10 *folders*, obteve os resultados mais satisfatórios de classificação, com baixos índices de erro ($AUC = 0.893$, $CA = 0.810$, $Precisão = 0.810$ e $Recall = 0,810$). Achados menos precisos foram encontrados nos modelos de *SVM* ($AUC = 0.419$, $CA = 0.499$, $Precisão = 0.421$ e $Recall 0.410$), de *Florestas Aleatórias* ($AUC =$

0,813, $CA = 0,737$, $Precis\tilde{a}o = 0,736$, $F1\ score = 0.736$ e $Recall = 0.737$) e k -NN ($AUC = 0.852$, $CA = 0.780$, $F1\ score = 0.700$, $Precis\tilde{a}o = 0,780$ e $Recall = 0,780$).

Após realizar a etapa de Treinamento e Validação, foi iniciada a etapa Teste como o uso do dataset *NeuIA*, elaborado pelos autores. O resultado da análise foi satisfatório, com índices de acertos também superiores no modelo *Neural Network* ($AUC = 0.987$, $CA = 0.930$, $F1 = 0.930$, $Precision = 0.931$ e $Recall = 0.930$). Demais resultados dos outros modelos são mostrados na Figura 11.

FIGURA 11 - Resultados obtidos na etapa Teste.




Fonte: Autores.

Foram produzidas outras análises estatísticas do algoritmo proposto como Matrizes de Confusão, Áreas sobre curva ROC, Análises de Calibração (*Calibration Plot*) e Curvas de Elevação (*Lift Curves*) para se averiguar a performance dos modelos utilizados. Foram consideradas pelos autores satisfatórias para os propósitos deste trabalho, conforme podemos

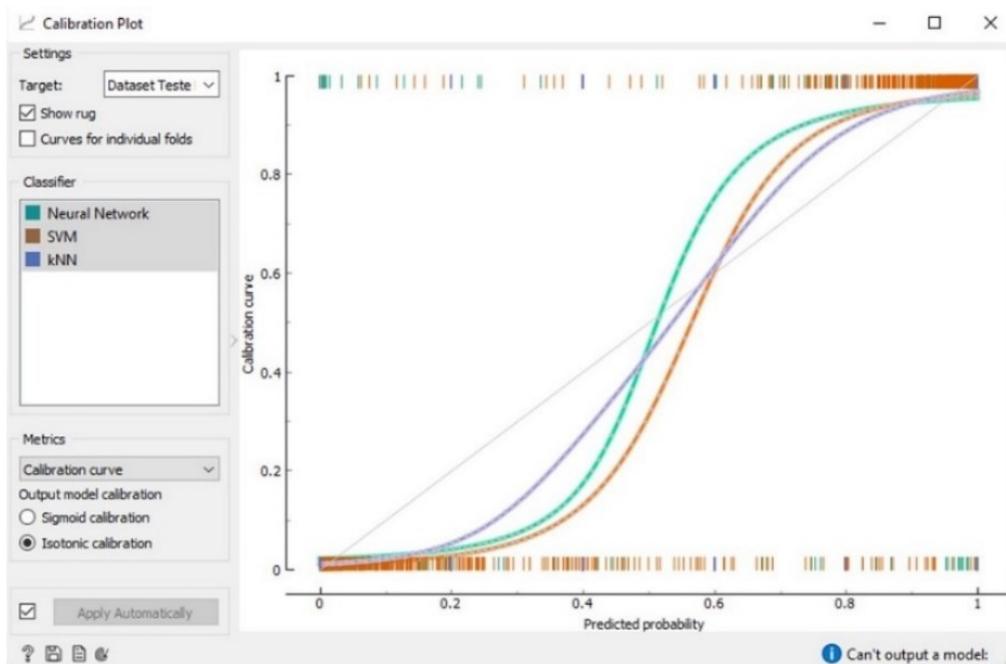
exemplificar com os gráficos das Áreas Sob a Curva ROC, mostrado na Figura 12, e das Análises de Calibração, mostrado na Figura 13.

FIGURA 12 - Áreas Sob a Curva ROC na etapa Teste.



Fonte: Autores.

FIGURA 13 - Análise de Calibração na etapa Teste.



Fonte Autores.

Entretanto, em virtude dos critérios de inclusão e exclusão para a elaboração do dataset testado, observamos viés positivo, relacionado à exclusão de achados incidentais, corpos estranhos e artefatos de movimento. Fatos estes, que em análises de vida real, podem ser representativos e dificultar a efetiva classificação. A elaboração de datasets mais robustos, com as devidas anotações de tais variáveis se fariam essenciais na transposição de tal recurso para estudos *in loco e in vivo*, segundo a opinião destes autores.

Modelos arquiteturais mais simples, como o SVM e as Florestas Aleatórias, tiveram maior quantidade de erros comparados ao modelo de *Neural Network* sobretudo na Etapa Treinamento e Validação, onde se empregou o dataset *RNSA* de maior robustez.

Contudo, todos os modelos apresentaram na etapa Teste resultados próximos usando o dataset *NeuIA*. Este fato pode sugerir que nem sempre é necessário se utilizar de complexos modelos de DL, de maior custo computacional e tempo de processamento, como Redes Neurais Convolucionais (CNN), para se desempenhar a tarefa solicitada. Para tal, pode-se utilizar de modelos mais simplificados de *Machine Learning*, mais bem regulados. De modo geral, a análise do experimento pelos autores é positiva para o objetivo delineado.

3.4 DISCUSSÃO

Em 1994, o jornalista do periódico *Science* David H. Freedman descreveu para a Sociedade Americana de Avanços da Ciência que “havia um florescente romance entre a substância cinzenta e o silício”. Descrevia-se então que modelos computacionais poderiam “simular” a atividade de neurônios humanos, remetendo-nos ao conceito de Redes Neurais Artificiais (*Artificial Neural Networks* - ANN ou simplifiadamente *Neural Networks*) (33).

Desde então inúmeros trabalhos foram produzidos com uso de IA na medicina. Em 2017, o primeiro *software* baseado em IA chamado *Arterys*®, foi aprovado *pele Food And Drugs Administration* (FDA) para uso comercial. Estima-se que até 2025 cerca de 109 bilhões de dólares sejam investidos na produção de *softwares* aplicando modelos de ML e DL para o mercado da saúde (34) (35).

O Aprendizado de Máquina ou “*Machine Learning*” (ML) é a modalidade de IA mais utilizada em pesquisas médicas. Utiliza algoritmos e modelos estatísticos treinados em dados de amostras para identificar padrões e fazer previsões a partir de novos dados. Abaixo exemplificamos alguns usos do ML na figura 14 (4).

O ML pode ser dividido em dois ramos principais: Aprendizado Superficial ou “*Single or Shallow Learning*” (única camada de neurônio artificial) e Aprendizado Profundo ou “*Deep Learning*” (múltiplas / ocultas camadas de neurônios artificiais), conforme podemos observar na figura 15 (35) (9).

O Aprendizado de Máquinas também pode ser subdividido em Supervisionado e não Supervisionado. Na figura 16, citamos vários modelos de ML, subdividindo-os nos dois tipos supracitados.


FIGURA 14 - Algumas diferenças e aplicações médicas do Machine Learning.



Fonte: Panesar,2020.

FIGURA 15 - Arquitetura básica Aprendizado Superficial e Profundo de Máquinas.

“Shallow Learning” - Aprendizado Superficial- Camada Única x “Deep Learning “- Aprendizado Profundo- Múltiplas Camadas



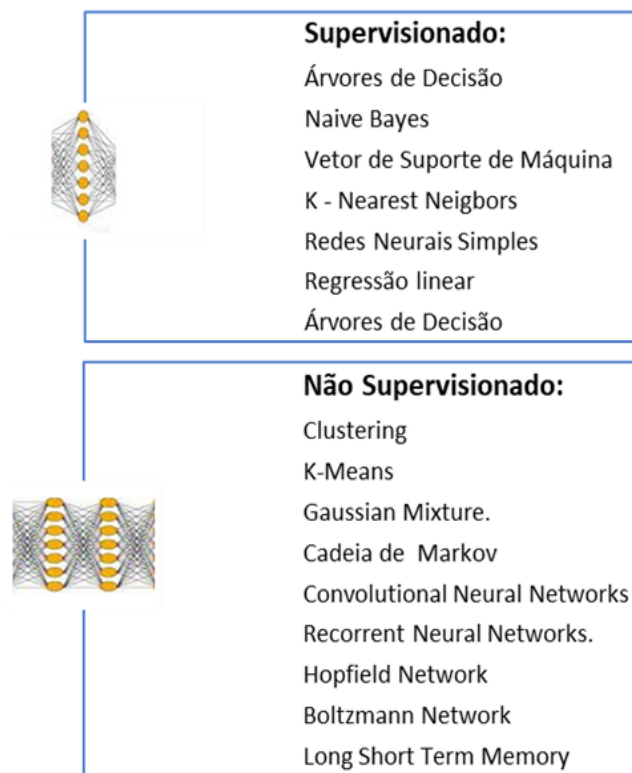
Fonte: Autor.

Nos modelos de Aprendizado de Máquina Supervisionados, os dados necessitam ser rotulados previamente por categorias (classificação) ou valores numéricos (regressão). Os

modelos de classificação supervisionada têm geralmente uma única camada de neurônio artificial (*Single Layer*). Citamos como exemplos destes modelos a Regressão Logística, *Naive -Bayes* , Árvores de Decisão (*Decision Trees*), Florestas Aleatórias (*Random Forests*), *K – Nearest Neibor* (KNN) e Máquinas de Vetores de Suporte (SVM) (36) (6) (37).

Já os modelos de Aprendizado de Máquinas não Supervisionados visam identificar padrões em dados não rotulados, organizando-os em conjuntos de dados complexos por grupos (*Clusters*) ou simplificando o número de variáveis (Redução de Dimensionalidade). Os modelos de classificação não supervisionada possuem múltiplas e escondidas camadas de neurônios artificiais (*Hidden Layers ou Deep Learning / DL*). São exemplos de DL as Redes Neurais Convolucionais (CNN), as Redes Neurais Recorrentes (RNN), dentre outras citadas na Figura 16 (38) (39) (8) (40).

FIGURA 16 - Exemplo de Machine Learnings supervisionados e não supervisionados.



É crescente o estudo e emprego do DL dentro da medicina. Diferentemente dos modelos de ML supervisionados, as representações e/ou resultados são descobertos automaticamente a partir de dados brutos. Múltiplas e profundas camadas de classificadores capturam as representações de dados, tanto de baixo, quanto de alto nível, permitindo que os *softwares* “aprendam” de forma mais rica abstrações de entradas (6) (37) (38).

O DL elimina a necessidade para engenharia manual de recursos como dados pré-trabalhados, também chamados de dados “rasos”. Permite modelos de aprendizagem profunda para descobrir naturalmente padrões previamente desconhecidos e generalizar melhor para novos dados. Pode utilizar de grandes fontes de dados, ou *Big Data*, para encontrar padrões ou comportamentos nem sempre óbvios, que num contexto clínico podem ser de salutar interesse a reconhecimento. De forma sumária então podemos compreender que o *Deep Learning* é uma das modalidades de *Machine Learning*, que por sua vez é uma das áreas de pesquisa em Inteligência Artificial, como exemplificado na Figura 17 (4) (8) (41) (42).

FIGURA 17 - Inteligência artificial, ML e DL: sumário.



Fonte: Pesapane, 2018.

Vários pesquisadores médicos vêm tentando utilizar dessa capacidade de classificação e identificação de padrões em benefício de seus pacientes. Inúmeras especialidades médicas,

mesmo fora do campo das neurociências, têm se beneficiado sobretudo de classificação de imagens. Como exemplo, podemos citar a Ortopedia, onde o diagnóstico de lesões do sistema osteoarticular e muscular é muito dependente de recursos de imagens como TCs e RNMs, onde o uso da IA tem se mostrado comparável à expertise humana na identificação de fraturas, lateralidade de lesões e partes do corpo comprometidas (30) (43) (44).

Em 2018, houveram mais de 6.000 publicações de trabalhos na base de dados *PUBMED* associando a IA (ML ou DL) à Neuroradiologia, Neurologia, Neurooncologia ou Neurocirurgia (9).

Especialmente na Neurologia e Neuroradiologia, onde há riqueza de dados, são inúmeras as frentes de trabalhos publicados usando como recursos o ML e o DL. Como exemplos podemos citar: o tratamento da Esclerose Múltipla (onde o cruzamento de dados clínicos, radiológicos e laboratoriais sugerem ser úteis para diagnósticos duvidosos, caracterização de progressão e decisões terapêuticas), a abordagem das Epilepsias de Difícil Controle (onde a análise sistemática dos perfis radiológicos, eletroencefalográficos e metabólicos cerebrais com SPECT / PET-CT, visando a identificação de bons ou maus candidatos à cirurgia), a condução da Doença de Alzheimer (onde dados clínicos, laboratoriais, genéticos e exames neuropsicológicos dão perspectivas ao correto diagnóstico, confundido com outras demências, além de riscos de progressões aceleradas e tratamentos), dentre outras (9) (38) (39) (40) (45) (46) (47).

A Neurocirurgia e suas interfaces com a Radiologia e a Oncologia muito se beneficiam do emprego da ML e DL. Promissores estudos como o processamento conjunto de múltiplas fontes de dados como exames de imagens, exames clínicos, laboratoriais e painéis genéticos tumorais por modelos de DL, buscando-se determinar o melhor tipo de tratamento a ser empregado, além de estimar o tempo de sobrevida de pacientes portadores tumores cerebrais malignos, são exemplos (48) (49) (50) (51) (52).

Várias outras frentes de pesquisa usando recursos computacionais e IA vêm sendo propostas em Neurocirurgia, podendo-se citar como exemplos: a classificação de lesões de diagnóstico radiológico difícil, a definição de bordas tumorais no planejamento de ressecções amplas ou múltiplas, no pós-operatório de ressecções tumorais visando identificar remanescentes tumorais, no controle pós-radioterápico para exclusão de recidivas ou pseudoprogredões, na correção de “*Brain Shifts*” intraoperatórios, no treinamento de médicos neurocirurgiões e residentes, dentre outras. Destaca-se a Radiogenômica, onde há crescente correlação de padrões de imagem de RNMs com variantes genéticas tumorais, afim de se determinar fatores preditivos diagnósticos, terapêuticos e prognósticos, antes mesmo da coleta de amostras teciduais por métodos invasivos (53) (54) (55) (56) (57) (58) (59) (60).

Particularmente na Neurotraumatologia, vários centros realizam trabalhos de classificação de imagens utilizando ferramentas de IA. Um estudo realizado no Reino Unido em 2020, utilizando imagens de 937 pacientes recrutados em mais de 60 centros clínicos europeus, construiu dois datasets de imagens de Tcs de crânio pós- TCEs, sendo 184 amostras para treinamento e 655 amostras para teste, submetendo-as à análise por Redes Convolucionais Neurais (CNN), um modelo de DL. Obteve-se sucesso, não somente identificando a presença de sangramentos (HICs), bem como os segmentando em subtipos, conforme localização (p.ex. extradural, subdural), e determinando sua volumetria. Outro trabalho indiano de 2018, utilizando datasets com 313.318 TCs de crânio, também encontrou resultados satisfatórios. Propoz dentro de suas conclusões que tais algoritmos fossem utilizados como método de triagem de HICs (11) (61) (62) (28).

Este estudo idealizou um algoritmo de IA seguindo as características dos estudos anteriores, focando nos potenciais benefícios do seu emprego na saúde pública. O Brasil possui um dos maiores serviços de saúde pública do mundo, o SUS , abrangendo de forma universal sua população. Suas principais premissas são: a Universalidade, a Integralidade e a Equidade

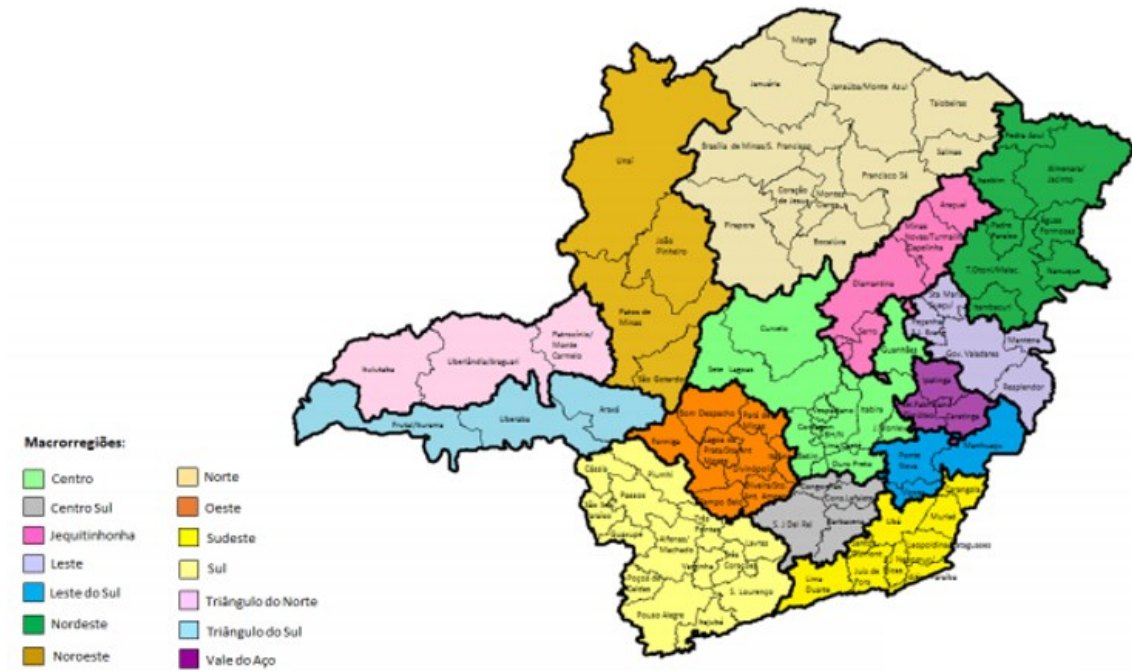
de atendimento à saúde dos brasileiros, assegurando-lhes os mesmos direitos e qualidades similares de atendimentos, sem distinção. Dentre seus pilares básicos encontram-se os princípios de Regionalização e Hierarquização dos serviços de saúde (63) (64).

Entende-se como Hierarquização os diferentes níveis de complexidade de atendimento à saúde que os municípios possuem. Existem centros de baixa, média e alta complexidade. Na sua lógica, quando um centro de baixa complexidade não possui condições de atenção a um paciente, ele é referenciado para um centro de maior complexidade, seja ele de média ou alta complexidade. Por conta de suas dimensões continentais, o princípio de Regionalização levou a divisão dos municípios em macrorregiões, onde poderiam ser encontrados no seu interior todos os três níveis de hierarquias (alta, média e baixa complexidade). A Figura 18 mostra a divisão do Estado de Minas Gerais (MG) em Macrorregiões Assistenciais de Saúde (65) (66).

Mesmo subdividido, as distâncias entre centros de baixa e alta complexidade ultrapassam centenas de quilômetros. Podemos citar a Macrorregião Noroeste / MG, com 33 municípios e uma de população com cerca de 500 mil habitantes. Como demonstrado na Figura 19, as transferências entre os municípios de Buritis (baixa complexidade) e Patos de Minas (única referência em Neurocirurgia na Macrorregião Noroeste e média complexidade), demoram, em média, 5 horas e 47 minutos por via terrestre (67).

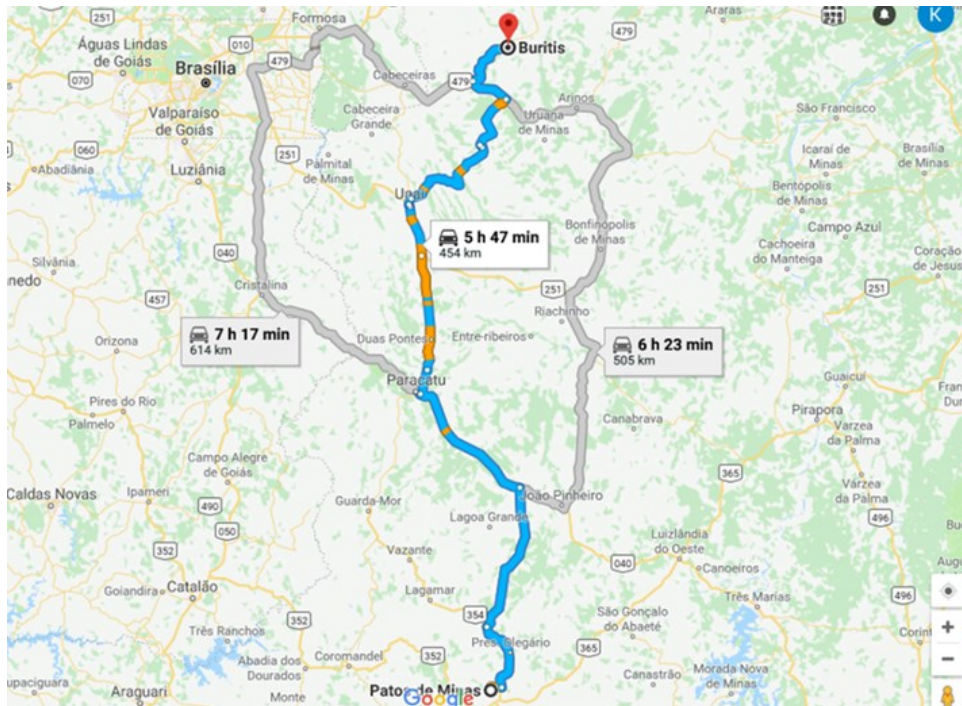
O processo de transferência de um centro de menor complexidade para um de maior complexidade dentro de uma macrorregião é gerida por um sistema de regulação de vagas de leitos que no estado de Minas Gerais ganhou o nome de SUS Fácil. É uma plataforma on-line onde são digitados os dados dos enfermos para posterior análise por um médico na central macrorregional de regulação, que analisa as características do caso, verifica a existência de vaga em hospitais de maior complexidade hierárquica e intermedia a transferência do enfermo (68) (69) (70) (65).

FIGURA 18 - Macrorregiões de Saúde / MG.



Fonte: site SES-MG, 2020.

FIGURA 19 - Exemplo de longa distância de transferência.



Fonte: Google Maps, 2021.

O processo necessita de dados digitados manualmente na plataforma para análise pelo médico regulador, tempo precioso quando o atendimento inicial e tratamento definitivo é crucial para redução de sequelas e mortalidade. Problemas podem provocar atrasos no atendimento como a falta de vagas em centros de tratamentos intensivos, de profissionais especializados e longas distâncias percorridas para o encaminhamento (71) (72)(73).

Na figura 20, é resumido algumas dificuldades relacionadas ao processo de Regulação e Transferência de pacientes vítimas de TCEs observadas pelo autor, servidor da única referência em Neurocirurgia da Macroregião Noroeste de MG.

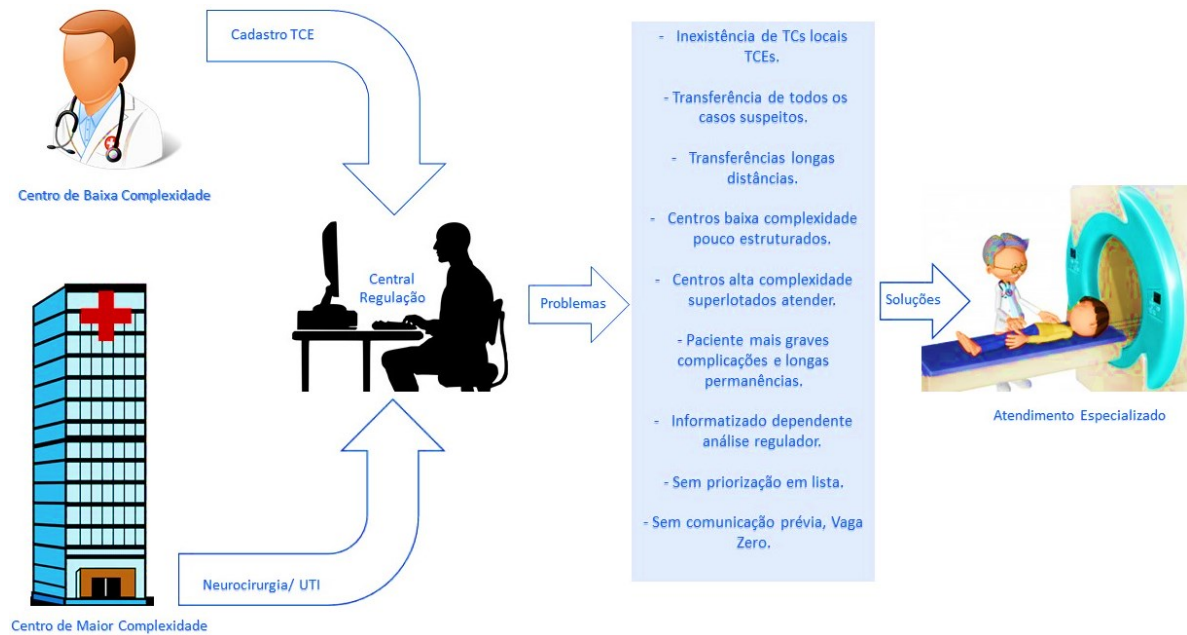
Dentro da abordagem neurocirúrgica dos TCEs, o tempo é de suma importância. Quarenta e cinco por cento das vítimas de TCEs graves falecem na primeira hora seguinte ao trauma, devido a lesões com efeito de massa ou distúrbios cardiocirculatórios. Um segundo pico, com 24% de óbitos, ocorre até a quarta hora do trauma, demonstrando que o acesso rápido à centros de tratamento com a disponibilidade de neurocirurgia é essencial para muitos enfermos. Atendimento ágil aos pacientes de TCEs é crucial para reduzir a morbimortalidade. É chamada de “Hora de Ouro” os primeiros 60 minutos seguintes ao trauma e os pacientes atendidos após esse período tem pior desfecho. Nos TCEs com Escala de Coma de Glasgow < 4, a mortalidade é de até 53% nos 6 meses seguintes ao acidente. Diagnósticos retardados, longas distâncias e dificuldades de transferências podem ter grande impacto no desfecho dos casos de TCEs conforme dados acima mencionados (71) (72) (10).

Poderíamos enumerar vários potenciais benefícios do desenvolvimento e utilização de ferramentas computacionais e de IA para detecção de HICs através de imagens de TCs nas cidades do interior, distantes dos grandes centros médicos (30).

Seu emprego alertaria os profissionais médicos e técnicos locais de condições potencialmente fatais, acelerando a tomada de providências quanto ao tratamento adequado, como cadastro e contato telefônico, ou por aplicativo, com as Centrais de Regulação de Leitos,

hospitais de média e alta complexidade (43).

FIGURA 20 - Racionalização fluxo regulação de leitos e alguns problemas.



Fonte: Autor.

Poderiam ser úteis como ferramenta de priorização de lista, permitindo análise ágil dos pacientes dentro da plataforma de regulação de leito SUS FÁCIL, inclusive com a possibilidade de inclusão futura de ferramentas de segmentação e volumetria de HICs, dados importantes quanto à decisão da necessidade ou não de intervenção neurocirúrgica emergencial (43).

Poderiam ser uma conexão a sistemas integrados de Telemedicina, onde agilizariam pareceres de médicos especialistas nos centros de maior complexidade ou nas Centrais de Regulação do SUS FÁCIL, em auxílio aos profissionais locais na condução de casos graves ou complexos (74).

Forneceriam sistemas automatizados de alerta remoto de neurocirurgiões nos centros de maior complexidade da ocorrência à distância de um TCE grave, antecipando assim cadastros e o preparo cirúrgico na instituição de destino para as necessidades terapêuticas antes de

concluída a transferência do enfermo, como por exemplo: reservas de leitos de terapia intensiva, reservas de hemoderivados, pré-cálculo de doses de medicações anestésicas, reserva de salas cirúrgicas, dentre outros (10) (4).

Reduziria o tempo de transferências para locais onde existam recursos disponíveis, evitaria deslocamentos desnecessários para a realização de TCs diagnósticas em centros de média e alta complexidade, aliviando-os de superlotação de suas emergências (21).

Como supracitado sobre a escassez de grandes estudos epidemiológicos nacionais, a integração de uma ferramenta de detecção de HICs num sistema estadual de regulação, proporcionaria valiosa coleta de dados para a elaboração de estudos de larga escala, pois permite conectividade de múltiplos centros a plataforma única de dados (43).

A grande quantidade e qualidade de dados gerados após análise por IA dos casos de TCEs, viabilizariam aos gestores de saúde de várias esferas, novas informações quanto às necessidades de recursos financeiros, aquisições de insumos, contratações de pessoal ou pactuações de serviços (63).

Geraria economia aos cofres públicos, pois reduziria os custos globais de internações (diárias, insumos, pessoal), pois melhorando a assistência aos pacientes com TCEs. Diagnósticos precoces e rápidos tratamentos determinariam menor potencial de complicações e hospitalizações prolongadas. Economias estas que poderiam ser revertidas na aquisição de novos aparelhos de TCs para localidades sem tal recurso e em pesquisa para o desenvolvimento e emprego de IA para a saúde (16).

A detecção automatizada de HICs, aliada a informação de elementos terapêuticos essenciais em neurotraumatologia como sua localização, volume e efeito compressivo encefálico, poderiam ser utilizados para o desenvolvimento de aplicativos ou programas contendo algoritmos de manejo clínico(11).

Poderiam ser utilizadas plataformas digitais economicamente acessíveis conectadas à

internet tais como notebooks, desktops e smartphones como auxiliares na formulação de estratégias terapêuticas destes enfermos. Ao abrir um aplicativo um neurocirurgião de uma capital poderia auxiliar ou mesmo dar a autorização de transferência de um enfermo de uma cidade do interior no tempo de um arraste de dedo indicador (75).

Através de preenchimento de formulários on-line, num futuro adicionados à ferramenta proposta, poderiam gerar dados que alimentariam datasets com importantes informações sobre a história clínica, exame físico e propedêutica adjuvante (exames radiográficos, eletrocardiográficos, laboratoriais, dentre outros) dos pacientes vítimas de TCEs. Tais informações poderiam traçar sugestões de algoritmos terapêuticos com recursos localmente disponíveis. Caso os recursos terapêuticos não existirem naquele centro, sugeririam aos gestores locais as adequações necessárias para a manutenção da vida e a redução de potenciais sequelas, como por exemplo ampliação de salas de emergências e aquisição de serviços de terapia intensiva. (9) (76).

Uma ferramenta de IA também poderia corroborar na própria prevenção de TCEs. Por exemplo, a alimentação do sistema com dados como locais de acidentes e seus mecanismos como: trechos de rodovias com altos índices de acidentes, locais com elevados índices de infrações de trânsito, tais como: avanços de esquinas, paradas obrigatórias, semáforos, o não uso de capacetes, dentre outros. Informações que num mundo interconectado, não são mais ficção científica (77).

3.5 CONCLUSÕES

O desenvolvimento de um algoritmo baseado em Inteligência Artificial para a detecção de Hemorragias Intracranianas pós-Traumas Cranioencefálicos se mostrou possível dentro dos limites estabelecidos pelos autores e com análises estatísticas satisfatórias.

Salienta-se que foram utilizados critérios de inclusão e exclusão que podem ocasionar vieses positivos de seleção, sobretudo correlacionadas à exclusão de elementos frequentes na prática neurocirúrgica cotidiana, como presença de artefatos de movimento, achados incidentais, número limitados de amostras, tipos de tomógrafos utilizados e centros envolvidos.

Entretanto os resultados são considerados satisfatórios pelos autores, sobretudo por poder demonstrar que soluções tecnológicas baseadas em IA, como o ML ou o DL, são exequíveis e podem ter grande impacto na saúde pública. Se incorporadas às plataformas como o SUSFÁCIL, potencialmente auxiliariam a rápida transferência de enfermos para centros de maior complexidade, seja pela rápida identificação de HICs (potencialmente fatais) ou pelo mecanismo de priorização em lista.

Além disto, inúmeros benefícios indiretos podem ser alcançados com a otimização do estudo da IA no contexto deste trabalho: a prevenção de traumas potencialmente fatais, a diminuição de gastos familiares e públicos, a redução de sofrimento e, sobretudo, a conservação da vida daqueles vitimados por TCEs em pequenos municípios dependentes da rede assistencial do SUS.

Conclui-se que o melhor estudo e aplicação de algoritmos de IA devem ser incentivados, inclusive por gestores de saúde pública, em virtude de seus inúmeros potenciais benefícios individuais, coletivos e institucionais.

3.6 BIBLIOGRAFIA

1. Raymond Geis J, Brady AP, Wu CC, Spencer J, Ranschaert E, Jaremko JL, et al. Ethics of artificial intelligence in radiology: Summary of the joint European and North American multisociety statement. *Radiology*. 2019;293(2):436–40.
2. Kaplan A, Haenlein M. Siri, Siri, in my hand: Who’s the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence. *Bus Horiz* [Internet]. 2019;62(1):15–25. Available from: <https://doi.org/10.1016/j.bushor.2018.08.004>
3. Leiva RG, Casari P, Östberg PO. Machine learning methods for reliable resource provisioning in edge-cloud computing: A survey. *ACM Comput Surv*. 2019;52(5).
4. Panesar SS, Kliot M, Parrish R, Fernandez-Miranda J, Cagle Y, Britz GW. Promises and Perils of Artificial Intelligence in Neurosurgery. *Neurosurgery*. 2020;87(1):33–44.
5. Moor J. Artificial Intelligence Conference: The Next Fifty Years. *AI Mag*. 2006;27(4):87–91.
6. Valliani AAA, Ranti D, Oermann EK. Deep Learning and Neurology: A Systematic Review. *Neurol Ther* [Internet]. 2019;8(2):351–65. Available from: <https://doi.org/10.1007/s40120-019-00153-8>
7. Giger L. Mammography and in. *Med Phys*. 1993;162:699–708.
8. Kaul V, Enslin S, Gross SA. History of artificial intelligence in medicine. *Gastrointest Endosc* [Internet]. 2020;92(4):807–12. Available from: <https://doi.org/10.1016/j.gie.2020.06.040>
9. Duong MT, Rauschecker AM, Mohan S. Diverse Applications of Artificial Intelligence in Neuroradiology. *Neuroimaging Clin N Am* [Internet]. 2020;30(4):505–16. Available from: <https://doi.org/10.1016/j.nic.2020.07.003>

10. Carney N, Totten AM, O'Reilly C, Ullman JS, Hawryluk GWJ, Bell MJ, et al. Guidelines for the Management of Severe Traumatic Brain Injury, Fourth Edition. *Neurosurgery*. 2017;80(1):6–15.
11. Monteiro M, Newcombe VFJ, Mathieu F, Adatia K, Kamnitsas K, Ferrante E, et al. Multiclass semantic segmentation and quantification of traumatic brain injury lesions on head CT using deep learning: an algorithm development and multicentre validation study. *Lancet Digit Heal* [Internet]. 2020;2(6):e314–22. Available from: [http://dx.doi.org/10.1016/S2589-7500\(20\)30085-6](http://dx.doi.org/10.1016/S2589-7500(20)30085-6)
12. Flanders AE, Prevedello LM, Shih G, Halabi SS, Kalpathy-Cramer J, Ball R, et al. Construction of a Machine Learning Dataset through Collaboration: The RSNA 2019 Brain CT Hemorrhage Challenge. *Radiol Artif Intell*. 2020;2(4):e209002.
13. Bordignon KC, Arruda WO. CT scan findings in mild head trauma: A series of 2,000 patients. *Arq Neuropsiquiatr*. 2002;60(2 A):204–10.
14. Tude Melo JR, Da Silva RA, Moreira ED. Characteristics of patients with head injury at Salvador City (Bahia - Brazil). *Arq Neuropsiquiatr*. 2004;62(3 A):711–4.
15. Oliveira SG, Spaziani AO, Frota RS, Freitas CJ, Matos MV, Souza KS, et al. Tratamento cirurgico de traumatismo cranioencefálico com fundamento no Brasil nos anos de 2014 a 2018. *Brazilian J Heal Rev*. 2020;3(2):1368–83.
16. CDC, NCIPC. Traumatic Brain Injury in News and Social Media. 2015; Available from: <https://www.cdc.gov/traumaticbraininjury/pdf/guide-to-writing-about-tbi-in-news-and-social-media-a.pdf>
17. Gaudêncio TG, Leão G de M. A epidemiologia do Traumatismo Crânio-Encefálico: Um Levantamento bibliográfico no Brasil. *Rev Neurociencias*. 2013;21(3):427–34.
18. Gardner A, Kay-Lambkin F, Stanwell P, Donnelly J, Williams WH, Hiles A, et al. A systematic review of diffusion tensor imaging findings in sports-related concussion. *J*

- Neurotrauma. 2012;29(16):2521–38.
19. Defillo A. Letter to the Editor. *J Neurosurg*. 2011;116(1):256–7.
 20. Santiago JS. Custo do Serviço de Ressonância Magnética nas entidades hospitalares: Um estudo comparativo no Hospitais da UnB e da UFRN. 2007;154.
 21. Azevedo YGP, Santos JVJ dos, Gomes AM, Carvalho DDR, Oliveira RMA de. Análise de Custeio em Exames de Diagnóstico por Imagem: Um Estudo de Caso Utilizando o Método Activity-Based Costing. *Rev Eletronica Gestão Saúde*. 2016;7(3):1106.
 22. Ganapathy K. Telemedicine in the management of head trauma: An overview. *Indian J Neurotrauma*. 2004;1(1):1–7.
 23. Ganapathy K, Abdul S, Nursetyo A. Artificial intelligence in neurosciences: A clinician’s perspective. *Neurol India*. 2018;66(4):934–9.
 24. Mariani AW, Pêgo-Fernandes PM. Telemedicina: Uma revolução tecnológica. *Sao Paulo Med J*. 2012;130(5):277–8.
 25. Bittencourt RJ, Hortale VA. Intervenções para solucionar a superlotação nos serviços de emergência hospitalar: uma revisão sistemática. *Cad Saude Publica*. 2009;25(7):1439–54.
 26. acknowledgments @ www.kaggle.com [Internet]. Available from: <https://www.kaggle.com/c/rsna-intracranial-hemorrhage-detection/overview/acknowledgments>
 27. Patarra AB. ToS - Termos de Uso - Lei Geral de Proteção de. 2020;
 28. Cruz Rivera S, Liu X, Chan AW, Denniston AK, Calvert MJ, Darzi A, et al. Guidelines for clinical trial protocols for interventions involving artificial intelligence: the SPIRIT-AI extension. *Nat Med*. 2020;26(9):1351–63.
 29. Mazurowski MA. Artificial Intelligence in Radiology: Some Ethical Considerations for Radiologists and Algorithm Developers. *Acad Radiol* [Internet]. 2020;27(1):127–9.

- Available from: <https://doi.org/10.1016/j.acra.2019.04.024>
30. Goldberg JE, Rosenkrantz AB, Richardson ML, Garwood ER, Lee Y, Li MD, et al. 乳鼠心肌提取 HHS Public Access. *Lancet Digit Heal* [Internet]. 2020;2(4):1–14. Available from: <http://arxiv.org/abs/1803.05854>
 31. Mongan J, Moy L, Kahn CE. Checklist for Artificial Intelligence in Medical Imaging (CLAIM): A Guide for Authors and Reviewers. *Radiol Artif Intell*. 2020;2(2):e200029.
 32. Ibrahim H, Liu X, Rivera SC, Moher D, Chan AW, Sydes MR, et al. Reporting guidelines for clinical trials of artificial intelligence interventions: the SPIRIT-AI and CONSORT-AI guidelines. *Trials*. 2021;22(1):1–5.
 33. Freedman DH. A romance blossoms between gray matter and silicon. *Science* (80-). 1994;265(5174):889–90.
 34. Crowley M. *A to Z of AI / ML : A Quick Introduction to Artificial Intelligence and Machine Learning Capabilities and Tools*. 2017;
 35. Cohen AB, Nahed B V, Sheth KN. *Neurology ® Clinical Practice Mobile medical applications in neurology*. 2013;52–60. Available from: www.neurology.org/cp
 36. Shaver MM, Kohanteb PA, Chiou C, Bardis MD, Chantaduly C, Bota D, et al. Deep learning in neuroradiology. *Brain* [Internet]. 2020;15(6):1–14. Available from: [http://dx.doi.org/10.1016/S2589-7500\(20\)30106-0](http://dx.doi.org/10.1016/S2589-7500(20)30106-0)
 37. McBee MP, Awan OA, Colucci AT, Ghobadi CW, Kadom N, Kansagra AP, et al. Deep Learning in Radiology. *Acad Radiol* [Internet]. 2018;25(11):1472–80. Available from: <https://doi.org/10.1016/j.acra.2018.02.018>
 38. Jiang F, Jiang Y, Zhi H, Dong Y, Li H, Ma S, et al. Artificial intelligence in healthcare: Past, present and future. *Stroke Vasc Neurol*. 2017;2(4):230–43.
 39. Zaharchuk G, Gong E, Wintermark M, Rubin D, Langlotz CP. Deep learning in neuroradiology. *Am J Neuroradiol*. 2018;39(10):1776–84.

40. Zhu G, Jiang B, Tong L, Xie Y, Zaharchuk G, Wintermark M. Applications of deep learning to neuro-imaging techniques. *Front Neurol.* 2019;10(AUG):1–13.
41. Pesapane F, Codari M, Sardanelli F. Artificial intelligence in medical imaging: threat or opportunity? Radiologists again at the forefront of innovation in medicine. *Eur Radiol Exp.* 2018;2(1).
42. Olthof AW, van Ooijen PMA, Rezazade Mehrizi MH. Promises of artificial intelligence in neuroradiology: a systematic technographic review. *Neuroradiology.* 2020;62(10):1265–78.
43. Richardson ML, Garwood ER, Lee Y, Li MD, Lo HS, Nagaraju A, et al. Noninterpretive Uses of Artificial Intelligence in Radiology. *Acad Radiol.* 2020;1–11.
44. Ramesh AN, Kambhampati C, Monson JRT, Drew PJ. Artificial intelligence in medicine. *Ann R Coll Surg Engl.* 2004;86(5):334–8.
45. Paldino MJ, Golriz F, Chapieski ML, Zhang W, Chu ZD. Brain network architecture and global intelligence in children with focal epilepsy. *Am J Neuroradiol.* 2017;38(2):349–56.
46. Li H, Habes M, Wolk DA, Fan Y. A deep learning model for early prediction of Alzheimer’s disease dementia based on hippocampal magnetic resonance imaging data. *Alzheimer’s Dement.* 2019;15(8):1059–70.
47. Qiu S, Joshi PS, Miller MI, Xue C, Zhou X, Karjadi C, et al. Development and validation of an interpretable deep learning framework for Alzheimer’s disease classification. *Brain.* 2020;143(6):1920–33.
48. Shaver MM, Kohanteb PA, Chiou C, Bardis MD, Chantaduly C, Bota D, et al. Optimizing neuro-oncology imaging: A review of deep learning approaches for glioma imaging. *Cancers (Basel).* 2019;11(6):1–14.
49. Lao J, Chen Y, Li ZC, Li Q, Zhang J, Liu J, et al. A Deep Learning-Based Radiomics

- Model for Prediction of Survival in Glioblastoma Multiforme. *Sci Rep* [Internet]. 2017;7(1):1–8. Available from: <http://dx.doi.org/10.1038/s41598-017-10649-8>
50. Titano JJ, Badgeley M, Schefflein J, Pain M, Su A, Cai M, et al. Automated deep-neural-network surveillance of cranial images for acute neurologic events. *Nat Med* [Internet]. 2018;24(9):1337–41. Available from: <http://dx.doi.org/10.1038/s41591-018-0147-y>
 51. Stoyanov GS, Dzhenkov DL. On the Concepts and History of Glioblastoma Multiforme - Morphology, Genetics and Epigenetics. *Folia Med (Plovdiv)*. 2018;60(1):48–66.
 52. Park JE, Kickingereder P, Kim HS. Radiomics and deep learning from research to clinical workflow: Neuro-oncologic imaging. *Korean J Radiol*. 2020;21(10):1126–37.
 53. Sarkiss CA, Germano IM. Machine Learning in Neuro-Oncology: Can Data Analysis From 5346 Patients Change Decision-Making Paradigms? *World Neurosurg* [Internet]. 2019;124:287–94. Available from: <https://doi.org/10.1016/j.wneu.2019.01.046>
 54. Buchlak QD, Esmaili N, Leveque J, Farrokhi F, Bennett C, Piccardi M, et al. Machine learning applications to clinical decision support in neurosurgery: an artificial intelligence augmented systematic review. 2020;1235–53.
 55. Valliani AAA, Ranti D, Oermann EK, Lao J, Chen Y, Li ZC, et al. Development and validation of an interpretable deep learning framework for Alzheimer’s disease classification. *Brain* [Internet]. 2019;15(6):1–14. Available from: <http://dx.doi.org/10.1038/s41598-017-10649-8>
 56. Dasgupta A, Gupta T. Radiogenomics in medulloblastoma: Can the human brain compete with artificial intelligence and machine learning? *Am J Neuroradiol*. 2019;40(5):E24–5.
 57. Kausar N, Belhaouari Samir B, Abdullah A, Ahmad I, Hussain M. A review of classification approaches using support vector machine in intrusion detection. *Commun Comput Inf Sci*. 2011;253 CCIS(PART 3):24–34.

58. Zeineldin RA, Karar ME, Coburger J, Wirtz CR. Towards automated correction of brain shift using deep deformable magnetic resonance imaging- intraoperative ultrasound (MRI-iUS) registration. 2020;6(1):1–5.
59. Winkler-Schwartz A, Yilmaz R, Mirchi N, Bissonnette V, Ledwos N, Siyar S, et al. Machine Learning Identification of Surgical and Operative Factors Associated with Surgical Expertise in Virtual Reality Simulation. *JAMA Netw Open*. 2019;2(8).
60. Perez-Breva L, Shin JH. Artificial Intelligence in Neurosurgery: A Comment on the Possibilities Letter to the editor Corresponding Author. 2019;16(4):640–2.
61. Aneja S, Chang E, Omuro A. Applications of artificial intelligence in neuro-oncology. *Curr Opin Neurol*. 2019;32(6):850–6.
62. Chilamkurthy S, Ghosh R, Tanamala S, Biviji M, Campeau NG, Venugopal VK, et al. Development and Validation of Deep Learning Algorithms for Detection of Critical Findings in Head CT Scans. 2018;1–18. Available from: <http://arxiv.org/abs/1803.05854>
63. BRASIL. Ministério da Saúde. Secretaria Nacional de Assistência à Saúde. ABC do SUS - Doutrinas e Princípios. *Secr Nac Assist à Saúde*. 1990;10.
64. Paim JS. Thirty years of the unified health system (SUS). *Cienc e Saude Coletiva*. 2018;23(6):1723–8.
65. Ministério da Saúde. Curso básico de regulação do Sistema Único de Saúde – SUS. 2016. 227 p.
66. Rodrigues M de S, Santana LF e, Silva EPG e, Gomes OV. Epidemiologia de traumatismo craniocéfálico em um hospital TT - Epidemiology of cranioencephalic trauma in a hospital. *Rev Soc Bras Clín Méd [Internet]*. 2018;16(1):21–4. Available from:
http://docs.bvsalud.org/biblioref/2018/06/884987/dezesseis1_vinteum.pdf%0Ahttp://fi-admin.bvsalud.org/document/view/z263g

67. SRS Patos de Minas _ Secretaria de Estado de Saúde de Minas Gerais.
68. Secretaria de Estado de Saúde de Minas Gerais. Sistema Estadual de Regulação Assistencial de Minas Gerais. 2005;1–40. Available from: http://www.mp.go.gov.br/portalweb/hp/2/docs/cartilha_sistema_estadual_regulacao_assistencial_mg.pdf
69. Torres SF de S, Belisário SA, Melo EM. A Rede de urgência e emergência da macrorregião norte de Minas Gerais: Um estudo de caso. Saude e Soc. 2015;24(1):361–73.
70. Campos GW de S. Future prospects for the SUS. Cienc e Saude Coletiva. 2018;23(6):1707–14.
71. BRUFFAERTS, R., MORTIER, Ph., KIEKENS, G., AUERBACH, R. P., CUIJPERS, P., DEMYTTENAERE, K., GREEN, J. G., NOCK, M. K., KESSLER RC. 乳鼠心肌提取 HHS Public Access. *Physiol Behav.* 2017;176(3):139–48.
72. Bansal V, Fortlage D, Lee JG, Costantini T, Potenza B, Coimbra R. Hemorrhage is more prevalent than brain injury in early trauma deaths: The golden six hours. *Eur J Trauma Emerg Surg.* 2009;35(1):26–30.
73. Sop T, Neurotrauma CE, Committee M, Approval PS, Approval PS, Center-tbi AG, et al. SOP manual for data access and publication requests. 2013;1–17.
74. Campos G, Macaya JFM, Malik AM, Cunha MA. de VII Encontro de Administração Informação - EnADTelemedicina na Saúde Pública Brasileira: Benefícios e OportunidadesI. 2020;(August).
75. Sanossian N, Starkman S, Liebeskind DS, Ali LK, Restrepo L, Hamilton S, et al. Simultaneous ring voice-over-internet phone system enables rapid physician elicitation of explicit informed consent in prehospital stroke treatment trials. *Cerebrovasc Dis.* 2009;28(6):539–44.

76. Hale AT, Stonko DP, Lim J, Guillaumondegui OD, Shannon CN, Patel MB. Using an artificial neural network to predict traumatic brain injury. *J Neurosurg Pediatr.* 2019;23(2):219–26.
77. Dapp TF, Heine V. Big Data — что такое системы больших данных? Развитие технологий Big Data. *IeeexploreIeeeOrg* [Internet]. 2012;561–6. Available from: <https://promdevelop.ru/big-data/>

4 CONCLUSÃO

O desenvolvimento de um algoritmo baseado em Inteligência Artificial para a detecção de Hemorragias Intracranianas pós-Traumas Cranioencefálicos se mostrou possível dentro dos limites estabelecidos pelos autores, com análises estatísticas satisfatórias, contemplando o objetivo geral proposto. Cabe salientar que também foram atingidos os objetivos específicos mencionados, destacando-se a compreensão dos conceitos básicos aplicados à IA, ML e DL.

Salienta-se que foram utilizados critérios de inclusão e exclusão que podem ocasionar vieses positivos de seleção, sobretudo correlacionados à exclusão de elementos frequentes na prática neurocirúrgica cotidiana, como a presença de artefatos de movimento, de achados intracranianos incidentais, número de amostras, tipos de tomógrafos e centros envolvidos. Anotações de datasets contemplando tais fatores, estudos multicêntricos e com uso de hardwares de múltiplos fabricantes, podem corrigir tal distorção.

Os resultados foram considerados satisfatórios pelos autores, sobretudo por poder demonstrar que soluções tecnológicas baseadas em IA, como o ML ou o DL, são exequíveis e podem ter grande impacto na saúde pública. Caso incorporadas às plataformas como o SUSFÁCIL, potencialmente auxiliariam à rápida transferência de enfermos para centros de maior complexidade, seja pela ágil identificação de HICs potencialmente fatais ou pelo mecanismo de priorização em lista.

Além disto, inúmeros benefícios indiretos podem ser alcançados com a otimização do estudo da IA no contexto deste trabalho: a prevenção de traumas potencialmente fatais, a diminuição de gastos familiares e públicos, investimentos em pesquisa e infraestrutura, e sobretudo, a conservação da vida das vítimas de TCEs em pequenos municípios e dependentes da rede assistencial do SUS.

Conclui-se que o melhor estudo e aplicação de algoritmos de IA devem ser incentivados, inclusive por gestores de saúde pública, em virtude de seus inúmeros potenciais benefícios individuais, coletivos e institucionais.

REFERÊNCIAS

1. ANEJA, S.; CHANG, E.; OMURO, A. Applications of artificial intelligence in neuro-oncology. **Current Opinion in Neurology**, [s. l.], v. 32, n. 6, p. 850–856, 2019. Doi: 10.1097/WCO.0000000000000761.
2. AZEVEDO, Y. G. P. et al. Análise de Custeio em Exames de Diagnóstico por Imagem: Um Estudo de Caso Utilizando o Método Activity-Based Costing. **Revista Eletronica Gestão & Saúde**, [s. l.], v. 7, n. 3, p. 1106, 2016.
3. BANSAL, V. et al. Hemorrhage is more prevalent than brain injury in early trauma deaths: The golden six hours. **European Journal of Trauma and Emergency Surgery**, [s. l.], v. 35, n. 1, p. 26–30, 2009.
4. BITTENCOURT, R. J.; HORTALE, V. A. Intervenções para solucionar a superlotação nos serviços de emergência hospitalar: uma revisão sistemática. **Cadernos de Saúde Pública**, [s. l.], v. 25, n. 7, p. 1439–1454, 2009.
5. BORDIGNON, K. C.; ARRUDA, W. O. CT scan findings in mild head trauma: A series of 2,000 patients. **Arquivos de Neuro-Psiquiatria**, [s. l.], v. 60, n. 2 A, p. 204–210, 2002.
6. BRASIL. MINISTÉRIO DA SAÚDE. SECRETARIA NACIONAL DE ASSISTÊNCIA À SAÚDE. ABC do SUS - Doutrinas e Princípios. **Secretaria Nacional de Assistência à Saúde**, [s. l.], p. 10, 1990.
7. BRUFFAERTS, R. et al. Neonatal rat myocardium (chinese). HHS Public Access. **Physiology & behavior**, [s. l.], v. 176, n. 3, p. 139–148, 2017.
8. BUCHLAK, Q. D. et al. Machine learning applications to clinical decision support in neurosurgery : an artificial intelligence augmented systematic review. [s. l.], p. 1235–1253, 2020.
9. CAMPOS, G. et al. **VII Encontro de Administração Informação - EnADTelemedicina na Saúde Pública Brasileira : Benefícios e Oportunidades**. [s. l.], n. August, 2020.
10. CAMPOS, G. W. de S. Future prospects for the SUS. **Ciencia e Saude Coletiva**, [s. l.], v. 23, n. 6, p. 1707–1714, 2018.
11. CARNEY, N. et al. Guidelines for the Management of Severe Traumatic Brain Injury,

- Fourth Edition. **Neurosurgery**, [s. l.], v. 80, n. 1, p. 6–15, 2017.
12. CDC; NCIPC. **Traumatic Brain Injury in News and Social Media**. [s. l.], 2015.
 13. CHILAMKURTHY, S. et al. **Development and Validation of Deep Learning Algorithms for Detection of Critical Findings in Head CT Scans**. [s. l.], p. 1–18, 2018.
 14. CHOWDHURY, S.; CHAKRABORTY, P. pratim. Universal health coverage - There is more to it than meets the eye. **Journal of Family Medicine and Primary Care**, [s. l.], v. 6, n. 2, p. 169–170, 2017.
 15. COHEN, A. B.; NAHED, B. V; SHETH, K. N. **Neurology® Clinical Practice Mobile medical applications in neurology**. [s. l.], p. 52–60, 2013.
 16. CROWLEY, M. **A to Z of AI / ML : A Quick Introduction to Artificial Intelligence and Machine Learning Capabilities and Tools**. [s. l.], 2017.
 17. CRUZ RIVERA, S. et al. Guidelines for clinical trial protocols for interventions involving artificial intelligence: the SPIRIT-AI extension. **Nature Medicine**, [s. l.], v. 26, n. 9, p. 1351–1363, 2020.
 18. DAPP, T. F.; HEINE, V. Big Data — What are big data systems? Technology development. **Ieeexplore.Ieee.Org**, [s. l.], p. 561–566, 2012.
 19. DASGUPTA, A.; GUPTA, T. Radiogenomics in medulloblastoma: Can the human brain compete with artificial intelligence and machine learning? **American Journal of Neuroradiology**, [s. l.], v. 40, n. 5, p. E24–E25, 2019.
 20. DEFILLO, A. Letter to the Editor. **Journal of Neurosurgery**, [s. l.], v. 116, n. 1, p. 256–257, 2011.
 21. DUONG, M. T.; RAUSCHECKER, A. M.; MOHAN, S. Diverse Applications of Artificial Intelligence in Neuroradiology. **Neuroimaging Clinics of North America**, [s. l.], v. 30, n. 4, p. 505–516, 2020.
 22. FLANDERS, A. E. et al. Construction of a Machine Learning Dataset through Collaboration: The RSNA 2019 Brain CT Hemorrhage Challenge. **Radiology: Artificial Intelligence**, [s. l.], v. 2, n. 4, p. e209002, 2020.
 23. FREEDMAN, D. H. A romance blossoms between gray matter and silicon. **Science**, [s. l.], v. 265, n. 5174, p. 889–890, 1994.
 24. GAMEIRO, G. et al. Inteligência Artificial a Serviço da Medicina Brasileira. **Revista**

- de Medicina**, [s. l.], v. 98, n. 1, p. i–iii, 2019.
25. GANAPATHY, K. Telemedicine in the management of head trauma: An overview. **The Indian Journal of Neurotrauma**, [s. l.], v. 1, n. 1, p. 1–7, 2004.
 26. GANAPATHY, K.; ABDUL, S.; NURSETYO, A. Artificial intelligence in neurosciences: A clinician’s perspective. **Neurology India**, [s. l.], v. 66, n. 4, p. 934–939, 2018.
 27. GARDNER, A. et al. A systematic review of diffusion tensor imaging findings in sports-related concussion. **Journal of Neurotrauma**, [s. l.], v. 29, n. 16, p. 2521–2538, 2012.
 28. GAUDÊNCIO, T. G.; LEÃO, G. de M. A epidemiologia do Traumatismo Crânio-Encefálico: Um Levantamento bibliográfico no Brasil. **Revista Neurociencias**, [s. l.], v. 21, n. 3, p. 427–434, 2013.
 29. GIGER, L. Mammography and in. **Medical Physics**, [s. l.], v. 162, p. 699–708, 1993.
 30. GOLDBERG, J. E. et al. Myocardial Extraction from Suckling Rats (chinese) HHS Public Access. **The Lancet Digital Health**, [s. l.], v. 2, n. 4, p. 1–14, 2020.
 31. HALE, A. T. et al. Using an artificial neural network to predict traumatic brain injury. **Journal of Neurosurgery: Pediatrics**, [s. l.], v. 23, n. 2, p. 219–226, 2019.
 32. HOULTON, S. How artificial intelligence is transforming healthcare. **Prescriber**, [s. l.], v. 29, n. 10, p. 13–17, 2018.
 33. JIANG, F. et al. Artificial intelligence in healthcare: Past, present and future. **Stroke and Vascular Neurology**, [s. l.], v. 2, n. 4, p. 230–243, 2017.
 34. KAPLAN, A.; HAENLEIN, M. Siri, Siri, in my hand: Who’s the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence. **Business Horizons**, [s. l.], v. 62, n. 1, p. 15–25, 2019.
 35. KAUL, V.; ENSLIN, S.; GROSS, S. A. History of artificial intelligence in medicine. **Gastrointestinal Endoscopy**, [s. l.], v. 92, n. 4, p. 807–812, 2020.
 36. KAUSAR, N. et al. A review of classification approaches using support vector machine in intrusion detection. **Communications in Computer and Information Science**, [s. l.], v. 253 CCIS, n. PART 3, p. 24–34, 2011.
 37. LAO, J. et al. A Deep Learning-Based Radiomics Model for Prediction of Survival in Glioblastoma Multiforme. **Scientific Reports**, [s. l.], v. 7, n. 1, p. 1–8, 2017.
 38. LEIVA, R. G.; CASARI, P.; ÖSTBERG, P. O. Machine learning methods for reliable

- resource provisioning in edge-cloud computing: A survey. **ACM Computing Surveys**, [s. l.], v. 52, n. 5, 2019.
39. LI, H. et al. A deep learning model for early prediction of Alzheimer's disease dementia based on hippocampal magnetic resonance imaging data. **Alzheimer's and Dementia**, [s. l.], v. 15, n. 8, p. 1059–1070, 2019.
40. MARIANI, A. W.; PÊGO-FERNANDES, P. M. Telemedicina: Uma revolução tecnológica. **Sao Paulo Medical Journal**, [s. l.], v. 130, n. 5, p. 277–278, 2012.
41. MCBEE, M. P. et al. Deep Learning in Radiology. **Academic Radiology**, [s. l.], v. 25, n. 11, p. 1472–1480, 2018.
42. MINISTÉRIO DA SAÚDE. **Curso básico de regulação do Sistema Único de Saúde – SUS**. [s.l: s.n.].
43. MONTEIRO, M. et al. Multiclass semantic segmentation and quantification of traumatic brain injury lesions on head CT using deep learning: an algorithm development and multicentre validation study. **The Lancet Digital Health**, [s. l.], v. 2, n. 6, p. e314–e322, 2020.
44. MOOR, J. Artificial Intelligence Conference : The Next Fifty Years. **AI Magazine**, [s. l.], v. 27, n. 4, p. 87–91, 2006.
45. OLTHOF, A. W.; VAN OOIJEN, P. M. A.; REZAZADE MEHRIZI, M. H. Promises of artificial intelligence in neuroradiology: a systematic technographic review. **Neuroradiology**, [s. l.], v. 62, n. 10, p. 1265–1278, 2020.
46. PAIM, J. S. Thirty years of the unified health system (SUS). **Ciencia e Saude Coletiva**, [s. l.], v. 23, n. 6, p. 1723–1728, 2018.
47. PALDINO, M. J. et al. Brain network architecture and global intelligence in children with focal epilepsy. **American Journal of Neuroradiology**, [s. l.], v. 38, n. 2, p. 349–356, 2017.
48. PANESAR, S. S. et al. Promises and Perils of Artificial Intelligence in Neurosurgery. **Neurosurgery**, [s. l.], v. 87, n. 1, p. 33–44, 2020.
49. PARK, J. E.; KICKINGEREDER, P.; KIM, H. S. Radiomics and deep learning from research to clinical workflow: Neuro-oncologic imaging. **Korean Journal of Radiology**, [s. l.], v. 21, n. 10, p. 1126–1137, 2020.
50. PEREZ-BREVA, L.; SHIN, J. H. **Artificial Intelligence in Neurosurgery: A**

- Comment on the Possibilities Letter to the editor Corresponding Author.** [s. l.], v. 16, n. 4, p. 640–642, 2019.
51. PESAPANE, F.; CODARI, M.; SARDANELLI, F. Artificial intelligence in medical imaging: threat or opportunity? Radiologists again at the forefront of innovation in medicine. **European Radiology Experimental**, [s. l.], v. 2, n. 1, 2018.
 52. QIU, S. et al. Development and validation of an interpretable deep learning framework for Alzheimer’s disease classification. **Brain**, [s. l.], v. 143, n. 6, p. 1920–1933, 2020.
 53. RAMESH, A. et al. Artificial intelligence in medicine. **Annals of the Royal College of Surgeons of England**, [s. l.], v. 86, n. 5, p. 334–338, 2004.
 54. RAYMOND GEIS, J. et al. Ethics of artificial intelligence in radiology: Summary of the joint European and North American multisociety statement. **Radiology**, [s. l.], v. 293, n. 2, p. 436–440, 2019.
 55. RICHARDSON, M. L. et al. Noninterpretive Uses of Artificial Intelligence in Radiology. **Academic Radiology**, [s. l.], p. 1–11, 2020.
 56. RODRIGUES, M. de S. et al. Epidemiologia de traumatismo craneoencefálico em um hospital TT - Epidemiology of cranioencephalic trauma in a hospital. **Rev. Soc. Bras. Clín. Méd**, [s. l.], v. 16, n. 1, p. 21–24, 2018.
 57. SANOSSIAN, N. et al. Simultaneous ring voice-over-internet phone system enables rapid physician elicitation of explicit informed consent in prehospital stroke treatment trials. **Cerebrovascular Diseases**, [s. l.], v. 28, n. 6, p. 539–544, 2009.
 58. SANTIAGO, J. S. **Custo do Serviço de Ressonância Magnética nas entidades hospitalares: Um estudo comparativo no Hospitais da UnB e da UFRN.** [s. l.], p. 154, 2007.
 59. SARKISS, C. A.; GERMANO, I. M. Machine Learning in Neuro-Oncology: Can Data Analysis From 5346 Patients Change Decision-Making Paradigms? **World Neurosurgery**, [s. l.], v. 124, p. 287–294, 2019.
 60. SECRETARIA DE ESTADO DE SAÚDE DE MINAS GERAIS. **Sistema Estadual de Regulação Assistencial de Minas Gerais.** [s. l.], p. 1–40, 2005.
 61. SHAVER, M. M. et al. Deep learning in neuroradiology. **Brain**, [s. l.], v. 15, n. 6, p. 1–14, 2020.
 62. SHAVER, M. M. et al. Optimizing neuro-oncology imaging: A review of deep learning

- approaches for glioma imaging. **Cancers**, [s. l.], v. 11, n. 6, p. 1–14, 2019.
63. SOP, T. et al. **SOP manual for data access and publication requests**. [s. l.], p. 1–17, 2013.
64. **SRS Patos de Minas _ Secretaria de Estado de Saúde de Minas Gerais**. [s.d.].
65. STOYANOV, G. S.; DZHENKOV, D. L. On the Concepts and History of Glioblastoma Multiforme - Morphology, Genetics and Epigenetics. **Folia Medica**, [s. l.], v. 60, n. 1, p. 48–66, 2018.
66. TITANO, J. J. et al. Automated deep-neural-network surveillance of cranial images for acute neurologic events. **Nature Medicine**, [s. l.], v. 24, n. 9, p. 1337–1341, 2018. Disponível em: <<http://dx.doi.org/10.1038/s41591-018-0147-y>>
67. TORRES, S. F. de S.; BELISÁRIO, S. A.; MELO, E. M. A Rede de urgência e emergência da macrorregião norte de Minas Gerais: Um estudo de caso. **Saúde e Sociedade**, [s. l.], v. 24, n. 1, p. 361–373, 2015.
68. TUDE MELO, J. R.; DA SILVA, R. A.; MOREIRA, E. D. Characteristics of patients with head injury at Salvador City (Bahia - Brazil). **Arquivos de Neuro-Psiquiatria**, [s. l.], v. 62, n. 3 A, p. 711–714, 2004.
69. VALLIANI, A. A. A. et al. Development and validation of an interpretable deep learning framework for Alzheimer’s disease classification. **Brain**, [s. l.], v. 15, n. 6, p. 1–14, 2019.
70. VALLIANI, A. A. A.; RANTI, D.; OERMANN, E. K. Deep Learning and Neurology: A Systematic Review. **Neurology and Therapy**, [s. l.], v. 8, n. 2, p. 351–365, 2019.
71. WINKLER-SCHWARTZ, A. et al. Machine Learning Identification of Surgical and Operative Factors Associated with Surgical Expertise in Virtual Reality Simulation. **JAMA Network Open**, [s. l.], v. 2, n. 8, 2019.
72. ZAHARCHUK, G. et al. Deep learning in neuroradiology. **American Journal of Neuroradiology**, [s. l.], v. 39, n. 10, p. 1776–1784, 2018.
73. ZEINELDIN, R. A. et al. **Towards automated correction of brain shift using deep deformable magnetic resonance imaging- intraoperative ultrasound (MRI-iUS) registration**. [s. l.], v. 6, n. 1, p. 1–5, 2020.
74. ZHU, G. et al. Applications of deep learning to neuro-imaging techniques. **Frontiers in Neurology**, [s. l.], v. 10, n. AUG, p. 1–13, 2019.

ANEXO 1

Normas para publicação no Jornal Brasileiro de Neurocirurgia

O Jornal Brasileiro de Neurocirurgia é o órgão oficial da Academia Brasileira de Neurocirurgia e se propõe a publicar artigos sobre Neurocirurgia e todas as ciências afins. Os volumes são anuais e compostos por 4 publicações trimestrais.

Assim, trabalhos inéditos, sob a forma de artigos originais, relatos de casos, artigos de revisão, notas breves e imagens clínicas, poderão ser aceitos, desde que não tenham sido enviados para publicação em outro periódico. Preferencialmente os artigos devem ser redigidos em inglês, com abstract em inglês e resumo em português ou Espanhol.

Alternativamente, poderão ser redigidos em português ou Espanhol, com respectivo resumo/*resumen* e um *abstract* em inglês (obrigatório). Todos os artigos também deverão conter título em inglês.

Todo e qualquer trabalho poderá receber modificações, para que se adapte à estrutura geral do Jornal. Os artigos que não se enquadrarem às normas ou que não forem adequados às necessidades editoriais do Jornal serão retornados ao autor correspondente, para as devidas adaptações.

Ricardo Ramina, MD, PhD Editor-Chefe

1) Submetendo seu artigo:

Somente serão aceitos artigos submetidos “*on line*” através da página <http://www.abnc.org.br> clicando-se no ícone “Envie seu Artigo”. Inicialmente, é necessário que o autor se cadastre e utilize os dados de login que foram enviados para o seu e-mail, através do ícone: “Cadastre-se para enviar seu artigo”.

Após o envio do artigo, o autor receberá um e-mail confirmando o recebimento. A seguir, o artigo passará pela nossa equipe de revisão para verificação de estrutura adequada às

normas abaixo. Em caso de adaptações necessárias, o autor receberá e-mail com a solicitação para continuidade do processo. Somente após atendimento ao checklist da equipe editorial, será iniciado o processo de revisão para aceite do artigo. Tabelas, algoritmos e gráficos: podem ser inseridos no arquivo do texto.

2) Tipos dos Artigos:

2.1) Artigos originais;

2.2) Relatos de casos;

2.3) Artigos de revisão;

2.4) Notas breves;

2.5) Imagens clínicas.

3) Aceite dos Artigos:

Os artigos serão aceitos após avaliação do Conselho Editorial e cumprimento das etapas de tramitação. Os artigos que não se enquadrarem às normas ou que não forem adequados às necessidades editoriais do Jornal serão retornados ao autor correspondente, para as adaptações necessárias. Inicialmente, avalia-se o rigor às normas de preparação dos artigos, a citação dos registros nos Conselhos e Comitês e o potencial para publicação.

Quando aprovado nas etapas anteriores o artigo será encaminhado para análise por pares (*peer review*) e os avaliadores os classificarão da seguinte forma: aceito, rejeitado ou requer revisões, seja de forma ou de conteúdo.

Os pareceres emitidos pelos avaliadores serão apreciados pelo Editor Científico, e posteriormente um parecer final será enviado ao autor correspondente.

4) Estrutura do Artigo:

- 4.1) Página de Rosto: títulos do artigo em português/espanhol e inglês (obrigatórios), nome completo do(s) autor(es) e da instituição a qual pertencem, seguidos de cidade e estado. Nome da instituição em que foi feito o estudo, cidade e país; dados completos de autor correspondente com endereço postal e e-mail.
- 4.2) Declaração de conflito de interesses e agência financiadora; se aplicável, aprovação do artigo ao Conselho Nacional de Saúde (CONEP-CNS) ou Comitê de Ética em Pesquisa da instituição onde foi realizado o trabalho ou citação do registro na Organização Mundial da Saúde (OMS) e do Comitê Internacional de Editores de Revistas Médicas (ICMJE).
- 4.3) Resumo/*Resumen* (português/espanhol) e *Abstract* em inglês (obrigatório), com máximo de 200 palavras, transmitindo a ideia geral da publicação e estruturado (introdução/ *introduction*, objetivo/ *objective*, métodos/ *methods*, resultados/*results* e conclusão/ *conclusion*). Artigo de Revisão, Notas Breves e Imagens clínicas dispensam a estruturação do resumo.
- 4.4) Palavras-Chave/ *Palabras-Clave* e *Key-words*: após Resumo/ *Resumen* e *Abstract* (mínimo de 3 e máximo de 5).
- 4.5) Texto: fonte Arial ou Times New Roman 12, sem recuo de parágrafo e justificado em espaço duplo.
- 4.6) Referências: normas Vancouver. Em ordem de citação, com numeração sobrescrita e arábica, por exemplo 1,20. Comunicações pessoais e trabalhos em preparação poderão ser citados no texto, mas não constarão das referências. Imagens Clínicas: máximo de 3 autores, texto de 150 palavras e 12 referências bibliográficas.

5) Exemplos de referências:

Fonte:http://www.nlm.nih.gov/bsd/uniform_requirements.html, International Committee of Medical Journal Editors (ICMJE) Recommendations for the Conduct, Reporting, Editing and

Publication of Scholarly Work in Medical Journals: Sample References Artigos de periódicos (COLOCAR DOI QUANDO EXISTENTE):

5.1 Até 6 autores:

Harbell J, Terrault NA, Stock P. Solid organ transplants in HIVinfected patients. *Curr HIV/AIDS Rep.* 2013 Sep;10(3):217-25. <http://dx.doi.org/10.1007/s11904-013-0170-z>.

5.2 Mais de 6 autores:

Patel MA, Kim JE, Theodros D, Tam A, Velarde E, Kochel CM, et al. Agonist anti-GITR monoclonal antibody and stereotactic radiation induce immune-mediated survival advantage in murine intracranial glioma. *J Immunother Cancer.* 2016; 4:28. <http://dx.doi.org/10.1186/s40425-016-0132-2>.

5.3 Livros:

Donald PJ, editor. *Surgery of the skull base.* Philadelphia: LippincottRaven; 1998. Breedlove GK, Schorfheide AM. *Adolescent pregnancy.* 2nd ed. Wiczorek RR, editor. White Plains (NY): March of Dimes Education Services; 2001.

5.4 Capítulos de livros:

Meltzer PS, Kallioniemi A, Trent JM. Chromosome alterations in human solid tumors. In: Vogelstein B, Kinzler KW, editors. *The genetic basis of human cancer.* New York: McGraw-Hill; 2002. p. 93- 113.

5.5 Dissertações e teses:

Borkowski MM. *Infant sleep and feeding: a telephone survey of Hispanic Americans [dissertation].* Mount Pleasant (MI): Central Michigan University; 2002.

5.6 Trabalhos apresentados em congressos, simpósios, encontros, seminários e outros:

Petersen R, Grundman M, Thomas R, Thal L. Use of titanium mesh for reconstruction of large anterior cranial base defects; 2004 July; United States, Philadelphia; 2004.

5.7 Artigos em periódicos eletrônicos:

Abood S. Quality improvement initiative in nursing homes: the ANA acts in an advisory role. Am J Nurs. 2002 Jun [cited 2002 Aug 12];102(6): [about 1 p.]. Available from: <http://www.nursingworld.org/AJN/2002/june/Wawatch.htm>Article

5.8 Textos em formato eletrônico:

Instituto Brasileiro de Geografia e Estatística. Estatísticas da saúde: assistência médico-sanitária. Disponível em: <http://www.ibge.gov.br>. Acessado em: 5/2/2004.

6) Responsabilidade Intelectual:

Ao submeter o artigo ao Jornal Brasileiro de Neurocirurgia automaticamente os autores transferem direitos de cópia à publicadora do periódico e assumem a responsabilidade intelectual e legal pelos resultados e pelas considerações apresentados.

Conforme resolução CNS nº 196/1996, o autor deve mencionar a submissão e a aprovação do artigo ao Conselho Nacional de Saúde (CONEP-CNS) ou Comitê de Ética em Pesquisa da instituição onde foi realizado o trabalho. No caso de ensaios clínicos, é obrigatória a citação do registro na Organização Mundial da Saúde (OMS) e do Comitê Internacional de Editores de Revistas Médicas (ICMJE). Publicação de Figuras

As figuras serão automaticamente publicadas em Preto e Branco. OBS: Para figuras coloridas, na Carta ao Editor deverá constar interesse para entrarmos em contato passando dados do recolhimento da taxa. Valores para impressão de foto colorida Quantidade 1, 2, 3, 4 e 5 ou mais: valores R\$ 500,00, R\$ 900,00, R\$ 1.200,00, R\$ 1.400,00 e R\$ 1.500,00.

7) Checklist de submissão:

Antes de enviar seu artigo, confira se todos os requisitos abaixo foram preenchidos:

7.1 Título em português ou Espanhol (segundo o idioma utilizado).

7.2 Título em inglês (obrigatório).

7.3 Página de rosto:

7.3.1 Nome da instituição em que foi feito o estudo, cidade e país;

7.3.2 Grau e filiação de todos os autores. E-mail de todos os autores é obrigatório para registro do DOI do artigo;

7.3.3 Dados completos de autor correspondente com endereço postal e e-mail;

7.3.4 Declaração de conflito de interesses e agência financiadora;

7.3.5 Declaração de submissão e a aprovação do artigo ao Conselho Nacional de Saúde (CONEP-CNS) ou Comitê de Ética em Pesquisa da instituição onde foi realizado o trabalho. Atenção: no texto do artigo também deverá constar esta informação;

7.3.6 No caso de ensaios clínicos, é obrigatória a citação do registro na Organização Mundial da Saúde (OMS) e do Comitê Internacional de Editores de Revistas Médicas (ICMJE). Atenção: no texto do artigo também deverá constar esta informação.

7.4 *Abstract/Resumo/Resumen*: introdução, objetivo, método, resultados, conclusão. (Artigo de Revisão, Notas Breves e Imagens clínicas dispensam a estruturação do resumo). *Keywords/Palavras-Chave/Palavras-clave*: no mínimo 3 a 5 termos.

7.5 Referências: ser numeradas por ordem de citação e sobrescritas antes da pontuação; Sistema Vancouver; incluir todos os autores quando até 6; quando mais, listar os 6 primeiros seguidos de “et al.”

7.6 Texto: fonte Arial ou Times New Roman 12, justificado e em espaço duplo.

7.7 Letter to the Editor: ofício submetendo seu artigo à apreciação contendo:

7.7.1 Declaração de que sua publicação é exclusiva neste periódico e enquanto não receber parecer negativo deverá informar ao editor para retirada dele;

7.7.2 Declaração de que transfere automaticamente direitos de cópia e permissões à publicadora do periódico e que assume a responsabilidade intelectual e legal pelos resultados e pelas considerações apresentados.

7.7.3 Declaração que não foi publicado anteriormente e nem está sob avaliação em outro periódico, todos os autores estão de acordo e, se aceito, não poderá ser publicado da mesma forma em qualquer idioma, sem o consentimento por escrito do *JBNc*.

7.8 Figuras: Em caso de existência de figuras coloridas, indicar seu interesse em publicar em preto e branco (padrão) ou coloridas (na dependência de depósito após aceite), as figuras devem ter alta resolução para impressão (300 DPI) em formato *JPEG*.

Atenção: Artigos submetidos sem estes pré-requisitos serão devolvidos aos autores para adequação antes de sua avaliação. Utilize o mesmo número de manuscrito para reenviar o arquivo. E-mails de todos os autores são obrigatórios para registro de DOI do artigo.

Fonte: https://www.abnc.org.br/jbnc_aut.php // Site oficial da ABNc.

ANEXO 2

CHECKLIST PARA ESTUDOS EM IMAGENS MÉDICAS USANDO IA (CLAIM):

1 TÍTULOS E ABSTRACTS:

1.1 Identificação como um estudo de metodologia de IA especificando a categoria de tecnologia usada (por exemplo, aprendizado profundo).

2 RESUMO:

2.1 Resumo estruturado do desenho do estudo, métodos, resultados e conclusões

3 INTRODUÇÃO:

3.1 Contexto científico e clínico, incluindo o uso pretendido e o papel clínico da abordagem de IA

3.2 Objetivos e hipóteses do estudo

4 MÉTODOS:

4.1 Estudo prospectivo ou retrospectivo

4.2 Objetivo do estudo, como criação de modelo, estudo exploratório, estudo de viabilidade, ensaio de não inferioridade.

5 DADOS:

5.1 Fontes de dados.

5.2 Critérios de elegibilidade: como, onde e quando os participantes ou estudos potencialmente elegíveis foram identificados (por exemplo, sintomas, resultados de testes anteriores, inclusão no registro, ambiente de atendimento ao paciente, localização, datas).

5.3 Etapas de pré-processamento de dados.

5.4 Seleção de subconjuntos de dados, se aplicável.

5.5 Definições de elementos de dados, com referências a elementos de dados comuns.

5.6 Métodos de desidentificação ou anonimização.

5.7 Como os dados ausentes foram tratados.

6 GROUND TRUTH:

6.1 Definição de padrão de referência de terreno de estudo, em detalhes suficientes para permitir a replicação.

6.2 Justificativa para escolher o padrão de referência (se houver alternativas).

6.3 Fonte de anotações de verdade fundamental; qualificações e preparação de anotadores.

6.4 Ferramentas de anotação.

6.5 Medição da variabilidade intra e interexaminadores; métodos para mitigar a variabilidade e / ou resolver discrepâncias.

7 PARTIÇÕES DE DADOS:

7.1 Tamanho de amostra pretendido e como foi determinado.

7.2 Como os dados foram atribuídos às partições; especificar proporções.

7.3 Nível em que as partições são disjuntas (por exemplo, imagem, estudo, paciente, instituição).

8 MODELOS:

8.1 Descrição detalhada do modelo, incluindo entradas, saídas, todas as camadas intermediárias e conexões.

8.2 Bibliotecas, estruturas e pacotes de software.

8.3 Inicialização de parâmetros do modelo (por exemplo, randomização, aprendizagem de transferência).

9 TREINAMENTO:

9.1 Detalhes da abordagem de treinamento, incluindo aumento de dados, hiperparâmetros, número de modelos treinados.

9.2 Método de seleção do modelo final.

9.3 Técnicas de montagem, se aplicável.

10 AVALIAÇÃO:

10.1 Métricas de desempenho do modelo.

10.2 Medidas estatísticas de significância e incerteza (por exemplo, intervalos de confiança).

10.3 Robustez ou análise de sensibilidade.

10.4 Métodos para aplicabilidade ou interpretabilidade (por exemplo, mapas de saliência) e como eles foram validados.

10.5 Validação ou teste em dados externos.

11 RESULTADOS:

11.1 Fluxo de participantes ou casos, usando um diagrama para indicar inclusão e exclusão.

11.2 Características demográficas e clínicas dos casos em cada partição.

12 DESEMPENHO DO MODELO:

12.1 Métricas de desempenho para modelo (s) ideal (is) em todas as partições de dados.

12.2 Estimativas de precisão do diagnóstico e sua precisão (como intervalos de confiança de 95%).

12.3 Análise de falha de casos classificados incorretamente.

13 DISCUSSÃO:

13.1 Limitações do estudo, incluindo potencial viés, incerteza estatística e generalização.

13.2 Implicações para a prática, incluindo o uso pretendido e / ou função clínica.

14 OUTROS:

14.1 Número de registro e nome do registro.

14.2 Onde o protocolo de estudo completo pode ser acessado.

14.3 Fontes de financiamento e outros apoios; papel dos financiadores.

Fonte: MONGAN J, MOY L, KAHN CE. Checklist for Artificial Intelligence in Medical Imaging (CLAIM): A Guide for Authors and Reviewers. **Radiol Artif Intell.** 2020;2(2):e200029.