

**UNIVERSIDADE FEDERAL DE UBERLÂNDIA
INSTITUTO DE BIOTECNOLOGIA
CURSO DE GRADUAÇÃO EM BIOTECNOLOGIA**

VITOR NUNES DE OLIVEIRA

**AVALIAÇÃO DE MODELOS COMPUTACIONAIS APLICADOS NA
CLASSIFICAÇÃO DE HEMORRAGIAS INTRACRANIANAS PÓS-TRAUMÁTICAS**

**PATOS DE MINAS - MG
AGOSTO DE 2022**

VITOR NUNES DE OLIVEIRA

**AVALIAÇÃO DE MODELOS COMPUTACIONAIS APLICADOS NA
CLASSIFICAÇÃO DE HEMORRAGIAS INTRACRANIANAS PÓS-TRAUMÁTICAS**

Monografia apresentada ao Instituto de Biotecnologia da Universidade Federal de Uberlândia como requisito final para a obtenção do título de Bacharel em Biotecnologia.

Prof. Dr. Laurence Rodrigues do Amaral

PATOS DE MINAS - MG

AGOSTO DE 2022

RESUMO

Os traumas crânio encefálicos (TCEs) são um problema para a sociedade pois resultam frequentemente em hemorragias intracranianas pós-traumáticas (HICs) responsáveis por elevada morbimortalidade. Seus desfechos são ainda piores quando incidem em pequenos municípios, distantes dos grandes centros, cujas infraestruturas hospitalares não contam com equipes profissionais especializadas. Nestes locais o reconhecimento destas patologias por vezes é retardado, ou mesmo não realizado, em virtude da necessidade de remoção dos pacientes para outros centros hospitalares. Algumas destas localidades possuem recursos para a aquisição de tomógrafos computadorizados, essenciais para o diagnóstico de HICs, porém possuem orçamentos insuficientes para a manutenção de quadros profissionais permanentes. Portanto, o desenvolvimento de uma ferramenta computacional capaz de reconhecer HICs baseada na classificação automatizada de imagens tomográficas realizadas nestes locais seria muito útil. Classificadores baseados em Redes Neurais Artificiais (ANN), SVM (*Support Vector Machines*) e KNN, já são amplamente utilizados como propostas a soluções tecnológicas em várias áreas. Devido a isso, estes três modelos foram testados como alternativas ao desenvolvimento de uma ferramenta computacional utilizada para a classificação de HICs. As previsões dos modelos ANN e KNN demonstraram estar corretas em 89 e 85 % das vezes, respectivamente, na fase de treinamento. Na fase de teste, as previsões dos três modelos se mostraram corretas em 98 % das vezes. Esse tipo de ferramenta possibilitaria que os serviços de urgência de pequenas cidades realizassem rápidos diagnósticos e transferissem seus enfermos para hospitais de maior complexidade quando realmente indicado.

Palavras-chave: Traumas crânio encefálicos (TCEs). Hemorragias intracranianas pós-traumáticas (HICs). Classificação de imagens. Inteligência artificial. Tomografia computadorizada do crânio.

ABSTRACT

Traumatic brain injuries (TBIs) are a problem for society as they often result in post-traumatic intracranial hemorrhages (ICHs) responsible for high morbidity and mortality. Its outcomes are even worse when they occur in small municipalities, far from large centers, whose hospital infrastructure does not have specialized professional teams. In these places, the recognition of these pathologies is sometimes delayed, or even not carried out, due to the need to transfer patients to other hospitals. Some of these locations have resources for the acquisition of computerized tomographs, essential for the diagnosis of ICHs, but they have insufficient budgets for the maintenance of permanent professional staff. Therefore, the development of a computational tool capable of recognizing ICHs based on the automated classification of tomographic images performed at these locations would be very useful. Classifiers based on Artificial Neural Networks (ANN), SVM (Support Vector Machines) and KNN, are already widely used as proposals for technological solutions in several areas. Because of this, these three models were tested as alternatives to the development of a computational tool used for the classification of ICHs. The predictions of the ANN and KNN models proved to be correct 89 and 85 % of the time, respectively, in the training phase. In the test phase, the predictions of the three models were correct 98% of the time. This type of tool would allow emergency services in small towns to perform quick diagnoses and transfer their patients to more complex hospitals when really indicated.

Keywords: Artificial Intelligence. Brain Trauma Injury. Computerized Tomography of the Skull. Intracranial Hemorrhages. Image Classification.

LISTA DE ABREVIATURAS E SIGLAS

ANN: *Artificial Neural Networks* / Redes Neurais Artificiais.
AUC: métrica, área sob a Curva Característica de Operação do Receptor / Curva ROC.
CNN: *Convolutional Neural Networks* / Redes Neurais Convolucionais.
DL: *Deep Learning* / Aprendizado Profundo de Máquinas.
F1 Score: métrica, média harmônica entre *Recall* e Precisão.
HICs: Hemorragias Intracranianas pós-Trauma Cranioencefálico.
IA: Inteligência Artificial.
MG: Estado de Minas Gerais.
ML: *Machine Learning* / Aprendizado de Máquinas.
MLP: *Multilayer perceptron* / *Perceptron* multicamadas.
KNN: *K- Nearest Neighbors* / Vizinhos Próximos.
ROC: métrica, *Receiving Operating Curve*.
SVM: *Support Vector Machine* / Vetor de Suporte de Máquinas.
TC: Tomógrafo Computadorizado.
TCs: Tomografias Computadorizadas.
RNMs: Ressonâncias Nucleares Magnéticas.

LISTA DE FIGURAS

Figura 1 - Linha do tempo do desenvolvimento e uso da inteligência artificial na medicina.	9
Figura 2 - Crescimento das publicações médicas em IA.....	10
Figura 3 - Hiperplano de separação e Vetores de Suporte no modelo SVM.....	13
Figura 4 - Arquitetura FeedForward de Camada Simples.....	15
Figura 5 - Arquitetura FeedForward de Camadas Múltiplas.....	15
Figura 6 - Arquitetura Recorrente ou Realimentada.	16
Figura 7 - Arquitetura de Estrutura Reticulada	16
Figura 8 - Etapas de processamento do modelo KNN.....	18
Figura 9 - TC de crânio sem achados de HICs (normal).....	20
Figura 10 - TC de crânio com a presença de achados de HICs.	20
Figura 11 - Origem e Notação dos datasets.....	22
Figura 12 - Estrutura proposta para o workflow.....	23
Figura 13 - Fluxo do processamento de dados no algoritmo: Importação das Imagens.	24
Figura 14 - Fluxo do processamento de dados no algoritmo: Incorporação de Imagens.	25
Figura 15 - Fluxo do processamento de dados no algoritmo: Modelos de Machine Learning.....	26
Figura 16 - Fluxo do processamento de dados no algoritmo: Redes Neurais Artificiais.	27
Figura 17 - Fluxo do processamento de dados no algoritmo: K- Nearest Neighbors.	28
Figura 18 - Fluxo do processamento de dados no algoritmo: Support Vector Machines.	29
Figura 19 - Fluxo do processamento de dados no algoritmo: Test and Score.....	30
Figura 20 - Fluxo do processamento de dados no algoritmo: Predictions.	31
Figura 21 - Resultados obtidos na etapa de Treinamento.....	32
Figura 22 - Resultados obtidos na etapa Teste.	33

SUMÁRIO

1 INTRODUÇÃO	7
1.1 Traumatismos Cranioencefálicos (TCEs).....	7
1.2 Inteligência Artificial, <i>Machine Learning</i> e <i>Deep Learning</i>	9
1.3 Obtenção de <i>datasets online</i>	11
1.4 Orange Data Mining (ODM)	12
1.5 Support Vector Machine (SVMs).....	12
1.6 <i>Artificial Neural Networks (ANNs)</i>	14
1.6.1 Arquitetura <i>FeedForward</i> de Camada Simples.....	14
1.6.2 Arquitetura <i>FeedForward</i> de Camadas Múltiplas.....	15
1.6.3 Arquitetura Recorrente ou Realimentada	16
1.6.4 Arquitetura com Estrutura Reticulada	16
1.7 K- <i>Nearest Neighbors</i> (KNN).....	17
1.8 IA e detecção de Hemorragias Intracranianas	18
OBJETIVOS.....	19
Objetivo Geral	19
Objetivos Específicos	19
2 MATERIAL E MÉTODOS.....	19
2.1 Obtenção e distribuição das imagens.....	19
2.2 Workflow e Orange Data Mining (ODM).....	23
2.3 Modelos de Classificação	26
2.3.1 Redes Neurais Artificiais (ANN)	26
2.3.2 K- <i>Nearest Neighbors</i> (kNN)	27
2.3.3 <i>Support Vector Machines</i> (SVMs)	28
2.4 Teste e validação dos modelos de classificação	29
3 RESULTADOS	31
4 DISCUSSÃO	33
5 CONCLUSÕES	35
REFERÊNCIAS	37

1 INTRODUÇÃO

1.1 Traumatismos Cranioencefálicos (TCEs)

Os TCEs podem ser definidos como qualquer lesão de caráter traumático, biomecânico e/ou molecular que afete o encéfalo, as meninges ou o crânio e seus constituintes neurovasculares. Esses traumas estão associados a elevados níveis de morbimortalidade, especialmente em pessoas com menos de 45 anos de idade estando geralmente relacionados a acidentes motociclísticos e em indivíduos com mais de 65 anos que passam a sofrer mais quedas com o decorrer do envelhecimento. Esse tipo de lesão pode levar a sequelas neurodegenerativas, incapacitantes e irreversíveis (RODRIGUES *et al.*, 2018).

Nos Estados Unidos da América, estima-se a incidência de cerca de 1.500.000 de casos por ano. Alguns estudos demonstram que cerca de 15% destes indivíduos que adentram os serviços de emergência apresentam TCEs como diagnóstico primário ou secundário. Em torno de 20% deles são considerados TCEs moderados ou graves, levando os pacientes a permanecerem internados em 50-70% das ocasiões. Este tipo de trauma apresenta mortalidade global estimada em cerca de 18/100.000 casos por ano (DEFILLO, 2011).

Os TCEs acometem todas as faixas etárias, havendo predomínio em indivíduos masculinos e jovens. São comuns as ocorrências tanto em capitais altamente desenvolvidas, com centros médicos de alta complexidade, quanto em pequenas cidades, sem qualquer infraestrutura especializada. São causas de grande sofrimento para suas vítimas e familiares, além de gerarem elevado custo econômico (CARNEY *et al.*, 2017).

Os avanços tecnológicos em neuroimagem como tomografias computadorizadas (TCs) e ressonâncias nucleares magnéticas (RNMs) foram essenciais para a compreensão de seus mecanismos fisiopatológicos, facilitando diagnósticos, aprimorando tratamentos e melhorando prognósticos (GARDNER *et al.*, 2012). Contudo, há fatores limitantes para sua aplicação em larga escala. O emprego de recursos de neuroimagem para diagnósticos dos TCEs em municípios pequenos, de orçamentos modestos, é dificultado pelo alto custo de aquisição da aparelhagem e sua instalação necessita de processos exaustivos e burocráticos. Além disso, também são limitadores para o amplo uso dessas tecnologias, a manutenção onerosa e a necessidade de contratação de profissionais especializados em seu manuseio como médicos, radiologistas, neurocirurgiões e técnicos (SANTIAGO, 2007).

A aquisição isoladamente de TCs para a detecção destas patologias seria uma opção economicamente viável para alguns destes municípios, todavia os elevados e permanentes custos operacionais de equipes médicas especializadas não seriam compatíveis com suas realidades orçamentárias (AZEVEDO *et al.*, 2016). Porém, as dificuldades para oferecer melhores condições diagnósticas para os pacientes vítimas de TCEs podem ser superadas por recursos tecnológicos. Um exemplo é o crescente uso da Telemedicina, no qual as longas distâncias e as graves doenças poderiam ser amenizadas através da tecnologia e altruísmo dos gestores de saúde (MARIANI; FERNANDES, 2012).

Atualmente, pacientes acometidos por TCEs de menor gravidade são transferidos por centenas de quilômetros para realizar exames nas grandes cidades desnecessariamente, sendo que, o atendimento médico especializado aos TCEs e a pronta identificação das hemorragias intracranianas pós-trauma craneoencefálico (HICs), por exemplo, poderiam ser realizados à distância, reduzindo a necessidade de transferência dos casos suspeitos. Caso houvesse um tomógrafo computadorizado na localidade de ocorrência, esses casos poderiam ser prontamente diagnosticados como TCEs de menor gravidade, sem a presença de HICs e que possuem tratamento menos complexo. Isso também reduziria os números de casos a serem avaliados nas grandes cidades, onde situam os hospitais de alta complexidade neurocirúrgica que geralmente se encontram sobrecarregados, tanto de casos que já seriam de sua alçada, quanto daqueles que a insuficiência de meios diagnósticos do interior os leva a atender (BITTENCOURT; HORTALE, 2009).

Uma forma de proporcionar melhor atenção as vítimas de TCEs a custos potencialmente acessíveis é o desenvolvimento de soluções tecnológicas que empregam, por exemplo, o uso de Inteligência Artificial (IA). Esses recursos, são cada dia mais utilizados em vários campos médicos e podem também ser de grande valia na neurotraumatologia (GAMEIRO *et al.*, 2019), (CHOWDHURY; CHAKRABORTY, 2017), (RAMESH *et al.*, 2004). O emprego destas ferramentas na neurocirurgia é crescente e são auxiliares na simplificação de processos diagnósticos e terapêuticos. Por meio da criação de soluções tecnológicas seria possível implementar a automação na detecção de hemorragias cerebrais pós-traumáticas em localidades onde existam TCs, mas não disponham médicos especialistas (neurocirurgiões e radiologistas) fisicamente disponíveis (HOULTON, 2018).

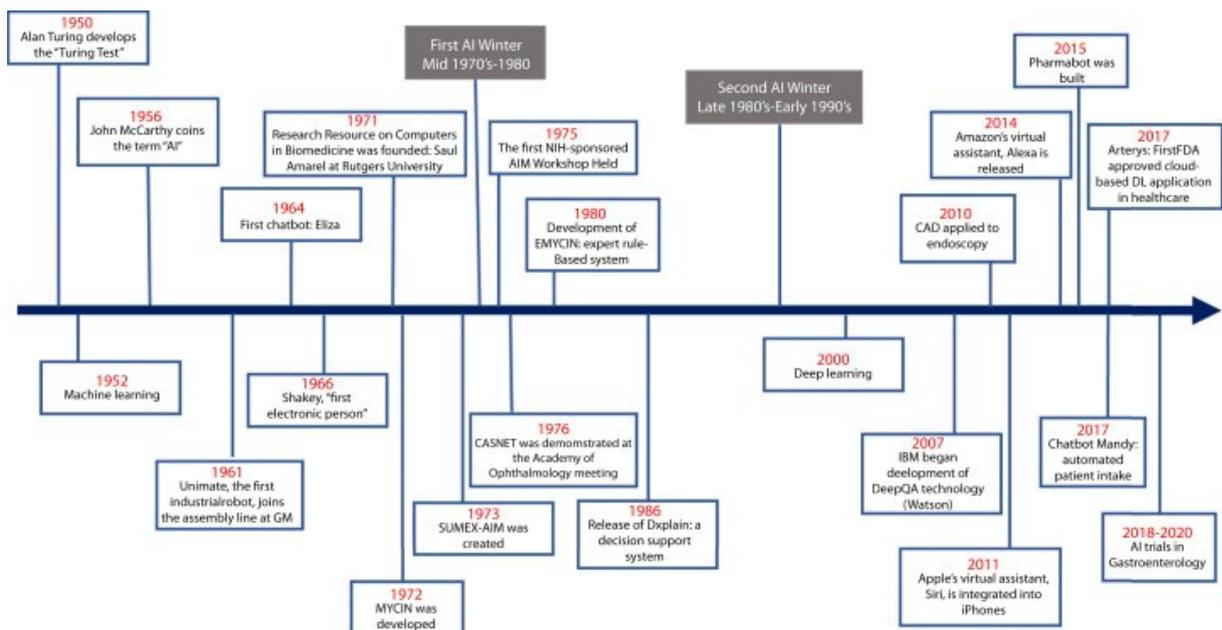
A detecção automatizada de HICs, aliada a informação de elementos terapêuticos essenciais em neurotraumatologia como sua localização, volume e efeito compressivo encefálico, poderiam ser utilizadas para o desenvolvimento de aplicativos ou programas contendo algoritmos de manejo clínico atualizados e individualizados (COHEN *et al.*, 2013).

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. Este tipo de tecnologia possibilitaria que, ao abrir um aplicativo, um neurocirurgião de uma capital possa auxiliar ou mesmo dar a autorização de transferência de um enfermo de uma cidade do interior para um grande centro, simplificando consideravelmente a complexidade de todo o processo envolvido em sua transferência (COHEN *et al.*, 2013).

1.2 Inteligência Artificial, *Machine Learning* e *Deep Learning*

Desde os anos 1970, quando surgiram os protótipos das Tomografias Computadorizadas (TCs), das Ressonâncias Nucleares Magnéticas (RNMs) e dos computadores pessoais, até chegarmos aos dias atuais houve um crescente interesse em pesquisas sobre Inteligência Artificial (IA) principalmente na Neuroradiologia. Ao longo do tempo, as crescentes melhorias dos recursos computacionais e o surgimento dos exames de imagens, contribuíram consideravelmente com os avanços observados na medicina conforme mostrado na Figura 1 (KAUL, 2020).

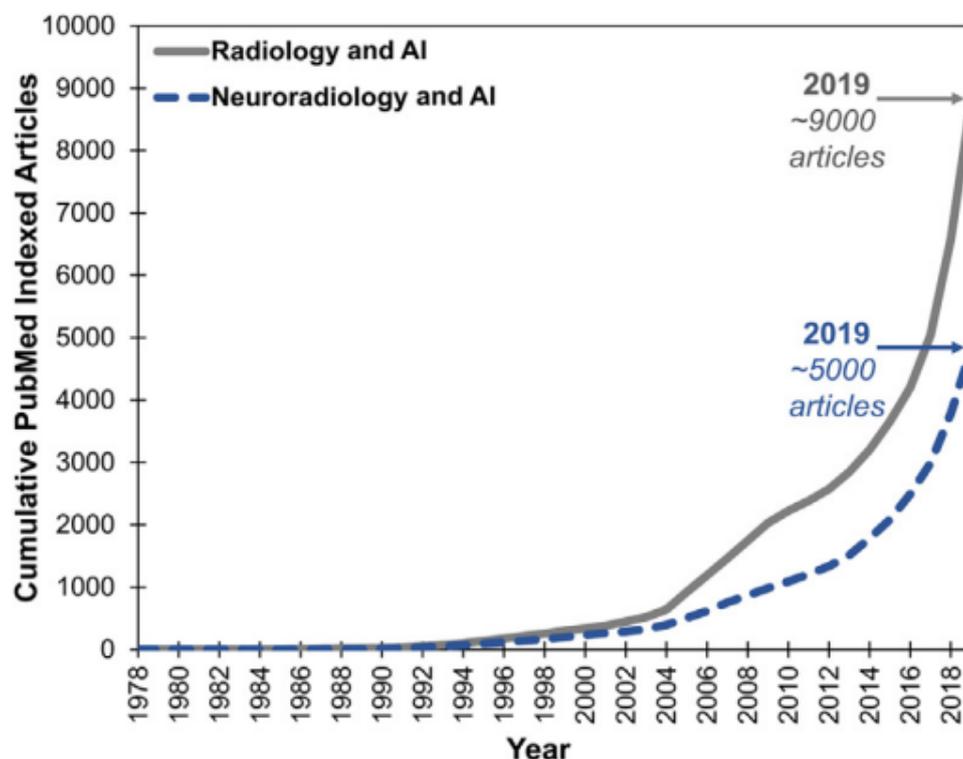
Figura 1 - Linha do tempo do desenvolvimento e uso da inteligência artificial na medicina.



Fonte: Kaul, 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 (Figura 2) (DUONG, 2020). A IA tornou-se, portanto, uma das áreas mais emergentes, populares e promissoras na ciência da computação. Essa tecnologia se baseia na capacidade de uma máquina de atuar como um humano e realizar tarefas que são geralmente feitas por pessoas. Devido a isso, o termo inteligência é aplicado, os computadores são programados para desenvolverem, portanto, a capacidade de compreender, de aprender e de agir de forma que possibilite que essas máquinas substituam os humanos em determinadas tarefas. Este tipo de tecnologia pode ser utilizada tanto para realização de tarefas repetitivas, que são normalmente mais simples, como para resolver questões mais complexas. Sendo assim, capazes de prever determinados comportamentos, tomar decisões baseadas em situações passadas e realizar um prognóstico assertivo sobre deliberações futuras (SILVA, 2021).

Figura 2 - Crescimento das publicações médicas em IA.



Fonte: Duong; Rauschecker; Mohan, 2020.

De forma mais geral, a IA trata-se de um conceito mais amplo que engloba áreas como o *Machine Learning* (ML) e o *Deep Learning* (DL). O ML é uma tecnologia que consegue aprimorar seu desempenho de forma independente por meio da experiência adquirida, sem necessitar da inferência humana. É possível descrevê-lo, portanto, como uma técnica que permite a aplicabilidade da IA, por meio da aplicação de vários de seus conceitos. Esse tipo de tecnologia possui um elevado poder de processamento de dados e, através da utilização desses algoritmos complexos, é capaz de realizar uma intensa coleta de dados para, posteriormente, interpretá-los e tomar decisões, executando tarefas de modo automatizado (SILVA, 2021). Modelos como as Redes Neurais Artificiais (ANN: *Artificial Neural Networks*), as Máquinas de Vetores de Suporte (SVM: *Support Vector Machine*) e o K-ésimo Vizinho mais Próximo (KNN: *K- Nearest Neighbors*) são exemplos de algoritmos de ML.

O DL, por outro lado, é o método da IA que se baseia nos algoritmos de Redes Neurais Artificiais. Esses algoritmos são capazes de simular o comportamento do cérebro humano em um nível extremamente avançado. As redes presentes nos modelos de DL atuam hierarquicamente através de camadas em cadeias que possibilitam as análises por meio de complexos processamentos de dados, utilizando de informações mais específicas e, muitas vezes, abstratas a observação humana. Nesse sentido, a IA representa, portanto, a capacidade das máquinas de pensarem e de replicarem o comportamento humano. O ML trata-se de uma ferramenta que possibilita a utilização da IA, ou seja, o software que permite sua aplicação. Enquanto que o DL compreende os parâmetros e a estrutura que viabiliza o treinamento dos algoritmos de ML (SILVA, 2021).

1.3 Obtenção de *datasets online*

Neste tipo de pesquisa, a etapa de aquisição dos dados geralmente consome a maior parte do tempo, além de ser burocrática e de difícil obtenção por necessitar da aprovação de rígidos comitês de ética. Contudo, para elaboração deste tipo de ferramenta, atualmente é possível encontrar e trabalhar com grandes conjuntos de dados que são disponibilizados *on-line* gratuitamente. O Kaggle, por exemplo, é uma plataforma do Google que permite aos usuários participar de competições de *Machine Learning* (Aprendizado de Máquina), explorando e publicando conjuntos de dados e tendo acesso a treinamentos de aprendizado de máquinas (MATOS, 2020). Esse tipo de plataforma oferece, portanto, uma alternativa aos estudantes,

pesquisadores e desenvolvedores de realizar estudos utilizando os dados que a própria plataforma disponibiliza, eliminando a etapa de aquisição.

1.4 Orange Data Mining (ODM)

Os modelos de ML, possuem, muitas vezes, uma estrutura matemática e computacional complexa e de difícil compreensão que, na maioria das vezes, afastam pesquisadores de outras áreas e impossibilitam que eles utilizem dessas ferramentas em seus estudos. Porém, atualmente, existem plataformas que possibilitam que estes profissionais também processem seus dados e utilizem de modelos de IA e ML em seus trabalhos e possam usufruir desses algoritmos já existentes, sem serem, necessariamente, desenvolvedores de ML. Essas ferramentas permitem, portanto, que eles realizem seus testes sem ter de compreender profundamente a estrutura matemática e computacional dessas técnicas.

Nesse sentido, o pacote ODM, por exemplo, é um software de código aberto utilizado para realizar análises, testes e para visualizar e estudar vários tipos de dados. A instalação inicial do *software* inclui vários algoritmos de Aprendizado de Máquina, pré-processamento e visualização de dados em alguns conjuntos de *widgets* que podem ser ligados aos seus dados e configurados para realizar *workflows*. Essa ferramenta fornece aos usuários a possibilidade de montagem de fluxos de trabalho compostos por componentes que, por exemplo, carregam as imagens de um determinado *dataset*, as incorporam em um espaço vetorial e analisam esses perfis de imagem para inferir agrupamentos ou classificações de imagens (GODEC *et al.*, 2019). Tanto o *software* quanto suas extensões utilizadas para a classificação de imagens estão disponíveis gratuitamente na página inicial do Orange (ORANGE, 2022).

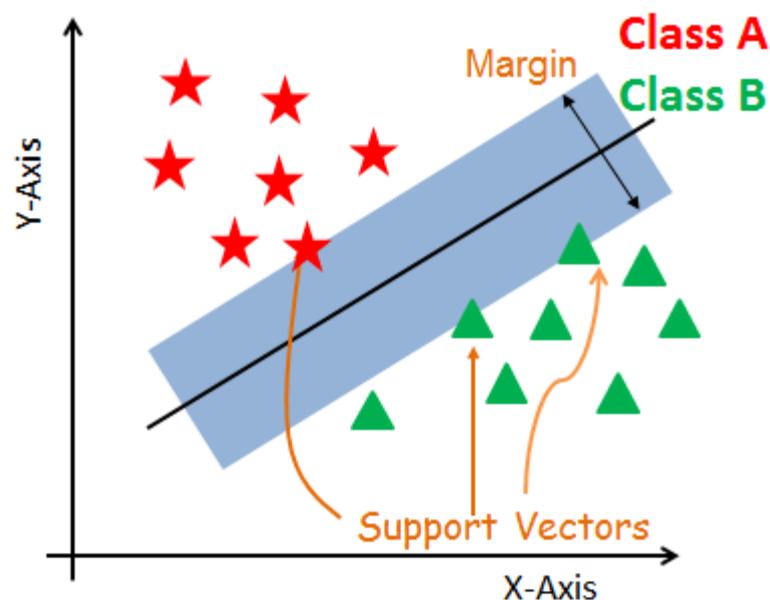
Esse tipo de ferramenta possibilita que vários modelos e algoritmos de classificação de imagens já estabelecidos possam ser testados como alternativas no desenvolvimento de novas ferramentas computacionais em outras áreas. Classificadores baseados em Redes Neurais Artificiais, SVM e KNN, por exemplo, já são amplamente aplicados em diversos segmentos de negócios, sendo utilizados como propostas a soluções tecnológicas em diversos setores como nas áreas de finanças, saúde, ciência política, reconhecimento de padrões em imagens e vídeos (LUZ, 2019).

1.5 Support Vector Machine (SVMs)

O SVM é um método proposto no início da década de 1990 para classificação de padrões e regressão não linear (CORTES; VAPNIK, 1995; AMORIM, 2007). Eles são fortemente baseados na teoria da aprendizagem estatística e consistem em uma implementação aproximada do método de minimização do risco estrutural (SILVA; LACERDA; SILVA, 2017).

Para ilustrar o funcionamento do modelo SVM, é possível utilizar o exemplo da classificação binária. Para duas classes de dados bem separadas, o aprendizado consiste em encontrar um hiperplano que separe as duas classes (hiperplano direcionado). Dessa forma, as instâncias da classe 1 estariam presentes em um dos lados do hiperplano, enquanto que as que representam a classe 2 estariam presentes do outro lado (cada classe com seu respectivo rótulo), conforme mostrado na Figura 3. Nesse sentido, o hiperplano direcionado definido pelo SVM está presente entre as duas classes e é responsável por separá-las. O termo Vetores de Suporte advém do fato que os pontos mais próximos em ambos os lados deste hiperplano de separação apresentam mais influência sobre sua posição (CAMPBELL; YING, 2011).

Figura 3 - Hiperplano de separação e Vetores de Suporte no modelo SVM.



Fonte: Naviani, 2019.

Em comparação com outras técnicas de aprendizado, os SVMs geralmente apresentam boa capacidade de generalização em problemas de classificação (AMORIM, 2007). De acordo com Bellman (1961), os SVMs não sofrem com o problema da dimensionalidade, ou seja, seus resultados podem ser melhores que as técnicas de aprendizado que sofrem deste problema, como é o caso das Redes Neurais Artificiais do tipo *Multilayer perceptron* (MLP).

1.6 Artificial Neural Networks (ANNs)

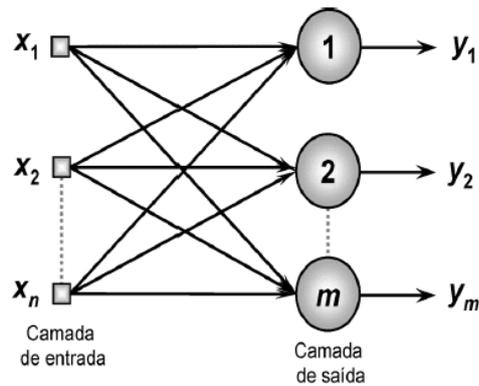
As ANN's são técnicas computacionais que tem seu conhecimento adquirido através da experiência, sendo elas inspiradas nos neurônios biológicos e nos sistemas nervosos (BARRETO, 1997). O primeiro modelo neuronal foi proposto por McCulloch e Pitts em 1943 e no final da década de 1950, Rosenblatt deu continuidade a esses trabalhos e foi responsável por desenvolver uma autêntica rede de múltiplos neurônios baseada em discriminadores lineares, a qual foi nomeada de *Perceptron* (KOVACS, 1997). Por se tratar de uma técnica que utiliza de aproximações de forma universal, a rede neural artificial mais comumente utilizada é a MLP, que além disso, possibilita a representação de qualquer função linear ou não linear.

Em uma ANN a camada de entrada recebe os dados a serem analisados e realiza sua correspondente associação com os pesos de entrada. A camada intermediária, por outro lado, é responsável por extrair as informações associadas ao sistema inferido e por realizar a maior parte do processamento dos dados. Ao final do processo, a camada de saída agrega os dados das camadas anteriores e ativa uma resposta adequada ao sistema. Dentre as arquiteturas mais usuais das ANN's pode-se citar as *FeedForward* de Camada Simples, de Camadas Múltiplas, as Recorrentes (Realimentadas) e as que possuem Estrutura Reticulada (PALMIERE, 2016).

1.6.1 Arquitetura *FeedForward* de Camada Simples

As ANN's que possuem arquitetura do tipo *FeedForward* de Camada Simples apresentam uma camada de entrada que está diretamente associada a um ou mais neurônios que são responsáveis por gerar a resposta de saída (Figura 4). Neste tipo de arquitetura, o fluxo de dados da ANN segue sempre em direção à camada de saída. Este tipo de modelo é geralmente utilizado em problemas de classificação de padrões e de filtragem (PALMIERE, 2016).

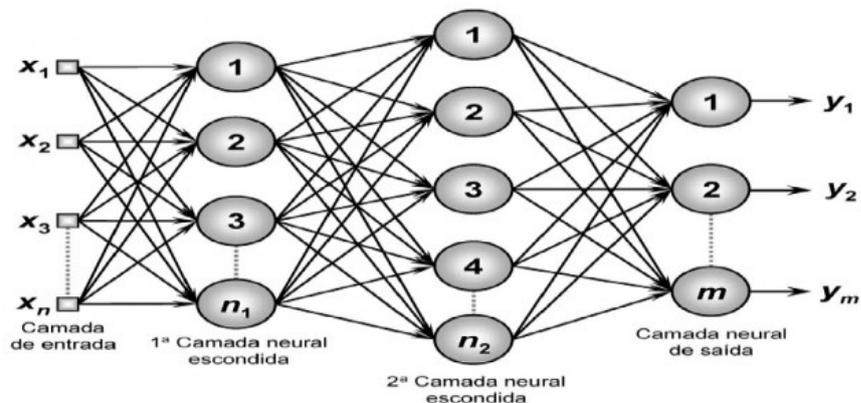
Figura 4 - Arquitetura FeedForward de Camada Simples.



Fonte: Palmiere, 2016.

1.6.2 Arquitetura *FeedForward* de Camadas Múltiplas

A arquitetura do tipo *FeedForward* de Camadas Múltiplas é constituída por uma ou mais camadas escondidas de neurônios (Figura 5). Elas são, geralmente, empregadas em problemas de aproximação de funções, na classificação de padrões e na identificação de sistemas. Além disso, são bastante utilizadas na robótica e para o controle e otimização de processos. Os tipos mais comuns são o *Perceptron* Multicamadas, e as Redes de Base Radial (PALMIERE, 2016).

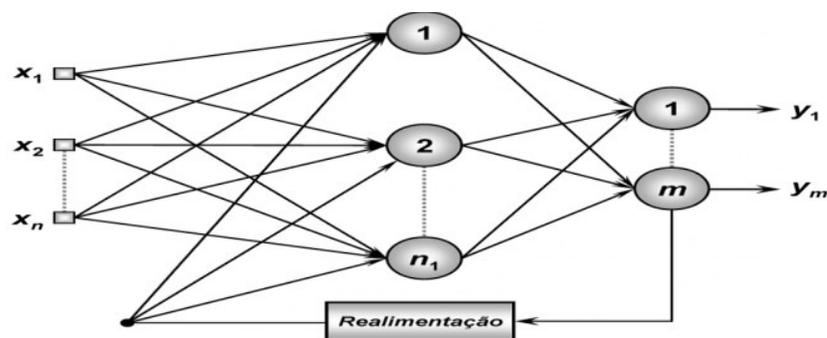
Figura 5 - Arquitetura *FeedForward* de Camadas Múltiplas.

Fonte: Palmiere, 2016.

1.6.3 Arquitetura Recorrente ou Realimentada

As ANN's Recorrentes são utilizadas no processamento de sistemas variantes no tempo em que suas saídas são realimentadas como sinais de entrada para outros neurônios (Figura 6). Este tipo de arquitetura é normalmente aplicado em previsões de séries temporais, na identificação de sistemas e na otimização e controle de processos. Os tipos mais comuns são o *Hopfield* e o *Perceptron* Multicamadas com Realimentação (PALMIERE, 2016).

Figura 6 - Arquitetura Recorrente ou Realimentada.

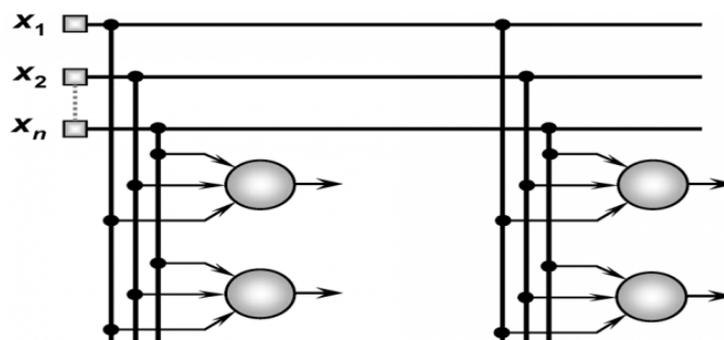


Fonte: Palmiere, 2016.

1.6.4 Arquitetura com Estrutura Reticulada

As ANN's de Estrutura Reticulada consideram a disposição espacial dos neurônios com o intuito de extrair as características do sistema. Sua localização espacial, portanto, é utilizada para ajustar seus pesos e limiares (Figura 7). Esses modelos são geralmente aplicados em problemas de agrupamento, no reconhecimento de padrões e na otimização de sistemas.

Figura 7 - Arquitetura de Estrutura Reticulada.



Fonte: Palmiere, 2016.

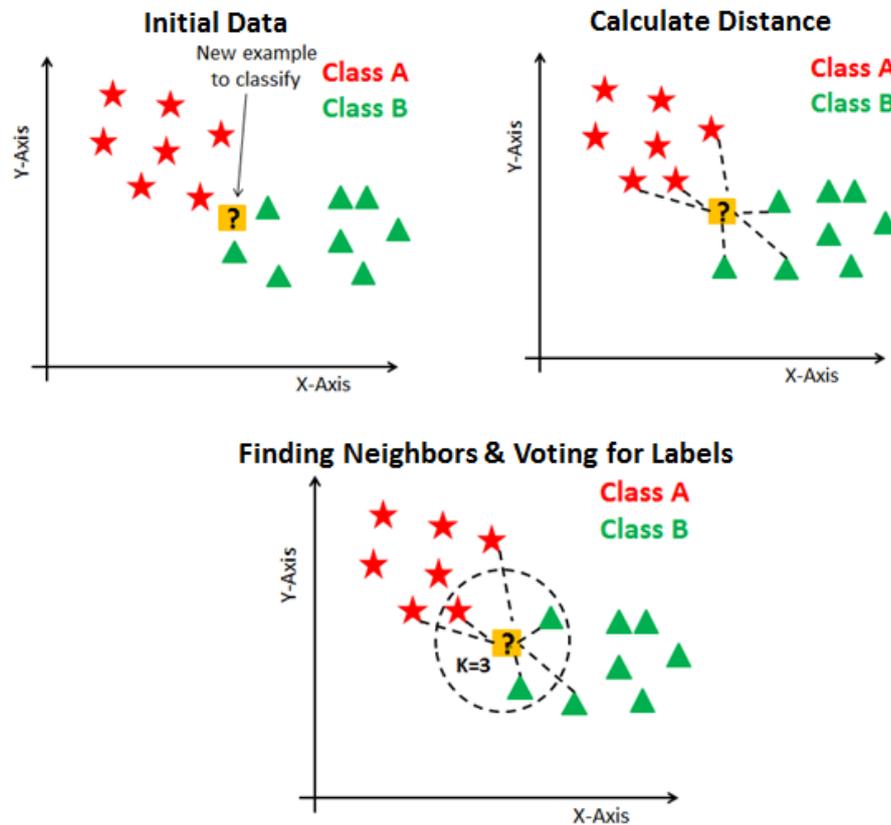
1.7 K- *Nearest Neighbors* (KNN)

O KNN é um dos algoritmos mais utilizados em ML e um dos que possui o processo de cálculo mais simples em suas classificações. Este modelo é composto por um algoritmo não paramétrico em que sua estrutura é determinada pelo *dataset* utilizado, ele pode ser aplicado tanto para tarefas de classificação quanto para regressão. Esta metodologia também é conhecida como de aprendizado lento (*Lazy Learning*). Os modelos do tipo *lazy*, não necessitam de dados de treinamento para se gerar o modelo, o que simplifica o processo inicial, mas por outro lado este tipo de procedimento faz com que seja necessário uma análise posterior mais apurada dos resultados (LUZ, 2019).

De forma geral, o KNN faz previsões usando diretamente o conjunto de dados de treinamento. Para uma nova instância (x), as previsões são feitas pesquisando todo o conjunto de treinamento para as K instâncias mais semelhantes (*Neighbors*) e resumindo a variável de saída para essas instâncias de K , nos modelos de classificação, esse pode ser o valor de classe do modo. Nesse sentido, para determinar quais das instâncias do K no conjunto de dados de treinamento são mais semelhantes a uma nova entrada, utiliza-se de uma medida de distância. A medida de distância mais popular para variáveis de entrada de valor real é a distância euclidiana (ILEOH, 2018).

Em resumo, o modelo armazena todo o conjunto de dados de treinamento utilizado como sua representação e faz previsões calculando a similaridade entre uma amostra de entrada e cada instância de treinamento (ILEOH, 2018). Eles realizam, portanto, primeiramente o cálculo da distância para que, em seguida, possa encontrar os pontos/vizinhos mais próximos e votar a *label* para o ponto a ser previsto (LUZ, 2019) (Figura 8).

Figura 8 - Etapas de processamento do modelo KNN.



Fonte: Luz, 2019.

1.8 IA e detecção de Hemorragias Intracranianas

O ML pode ser uma ferramenta útil na rápida detecção de padrões de imagem de patologias ameaçadoras a vida, como as HICs secundárias aos TCEs. Em emergências, a rápida detecção de HICs pode ser 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). Nesse sentido, a aplicação de soluções tecnológicas, como algoritmos de ML capazes de identificar HICs em TCs, poderiam reduzir o impacto dos TCEs sobre a sociedade, sobretudo quando aplicados em um cenário de escassez de recursos assistenciais, como cidades com infraestrutura hospital de baixa complexidade.

Este estudo visa, portanto, estudar, desenvolver e analisar comparativamente três algoritmos de IA que poderiam ser capazes de diferenciar imagens de TCs de crânio portadoras de HICs de controles normais e analisar seus potenciais benefícios ao cenário hospitalar brasileiro.

OBJETIVOS

Objetivo Geral

Estudar, entender e comparar os diversos modelos de classificação de imagens disponíveis no software Orange Data Mining. Avaliar quais destes modelos seriam mais precisos e adequados para o desenvolvimento futuro de um software utilizado para a classificação de HICs.

Objetivos Específicos

- Compreender os conceitos básicos relacionados à Inteligência Artificial, Aprendizado de Máquina, Mineração de Dados e modelos de classificação de imagens;
- Desenvolver habilidades para construir, prospectar, anotar e anonimizar *datasets* de imagem;
- Desenvolver habilidades para manejo de *softwares* básicos que transformam imagens clínicas em dados computacionais capazes de serem analisadas por modelos de *Machine Learning*;
- 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 teste;
- Compreender a estrutura básica dos modelos de *Machine Learning* empregados na pesquisa: Redes Neurais Artificiais, Máquinas de Vetores de Suporte e *K – Nearest Neighbors*.

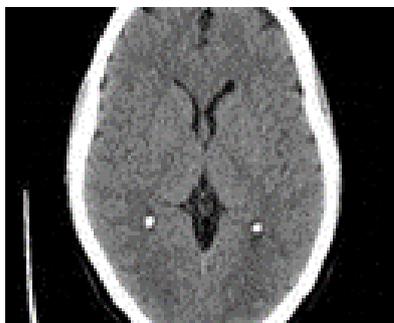
2 MATERIAL E MÉTODOS

2.1 Obtenção e distribuição das imagens

Para a realização do estudo, foram escolhidas imagens de TCs de crânio sem contraste de vítimas de TCEs atendidas nas emergências do Hospital Regional Antônio Dias – Patos de Minas / Minas Gerais, no período anterior ao ano de 2018. A aquisição das imagens foi feita somente após a aprovação dos Comitês de Ética e Pesquisa (CEPs) das instituições parceiras, não houve conflitos de interesses, sendo o trabalho financiado pelos próprios autores.

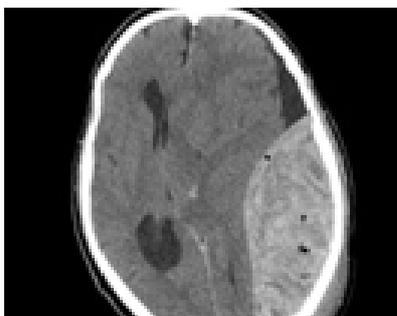
Para montagem do *dataset* foram incluídas somente imagens de TCs de crânio normais (Figura 9) e com achados de HICs (Figura 10). Essas imagens foram coletadas de duas fontes distintas: Hospital Regional Antônio Dias e Kaggle. O conjunto de dados utilizado para o treinamento dos modelos foi obtido através da 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 realizado, portanto, o *download* do *RSNA Intracranial Hemorrhage Detection*, um *dataset* aberto que foi disponibilizado pela Sociedade Americana de Neuroradiologia (ASNR), em colaboração com várias instituições de pesquisa (RSNA, 2019).

Figura 9 - TC de crânio sem achados de HICs (normal).



Fonte: próprio autor.

Figura 10 - TC de crânio com achados de HICs.



Fonte: próprio autor.

Em relação ao conjunto utilizado no Teste dos modelos, foram utilizadas imagens obtidas de laudos oficiais realizados por radiologistas colaboradores. A aquisição das imagens foi feita a partir de dois tomógrafos *Phillips Brilliance*® de 16 e 64 canais adquiridas das plataformas de imagens e laudos Synapse® e Arya® / PACS® (*Picture Archiving and Communication System*) pertencentes às instituições hospitalares parceiras (FLANDERS *et al.*, 2020).

Os dados obtidos na plataforma Kaggle se encontravam, originalmente, em formato *DICOM.3*® (*Digital Imaging and Communications in Medicine*). Portanto, para a realização dos testes, as imagens foram convertidas para o formato JPEG (*Joint Photographic Experts Group*). Após a conversão, os conjuntos 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.

As TCs de controles clínicos ou pós-operatórios foram excluídas. Não foram avaliados dados pessoais dos pacientes, portanto, sem distinção de gênero, idade ou etnia, apenas dados brutos e anonimizados foram utilizados. Não foram utilizadas imagens de menores de dezoito anos e nem imagens com grandes lesões traumáticas de face, como fraturas, lacerações ou hematomas, artefatos de movimento, corpos estranhos e achados incidentais de patologia intracraniana. Achados intracranianos incidentais foram definidos como: 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.

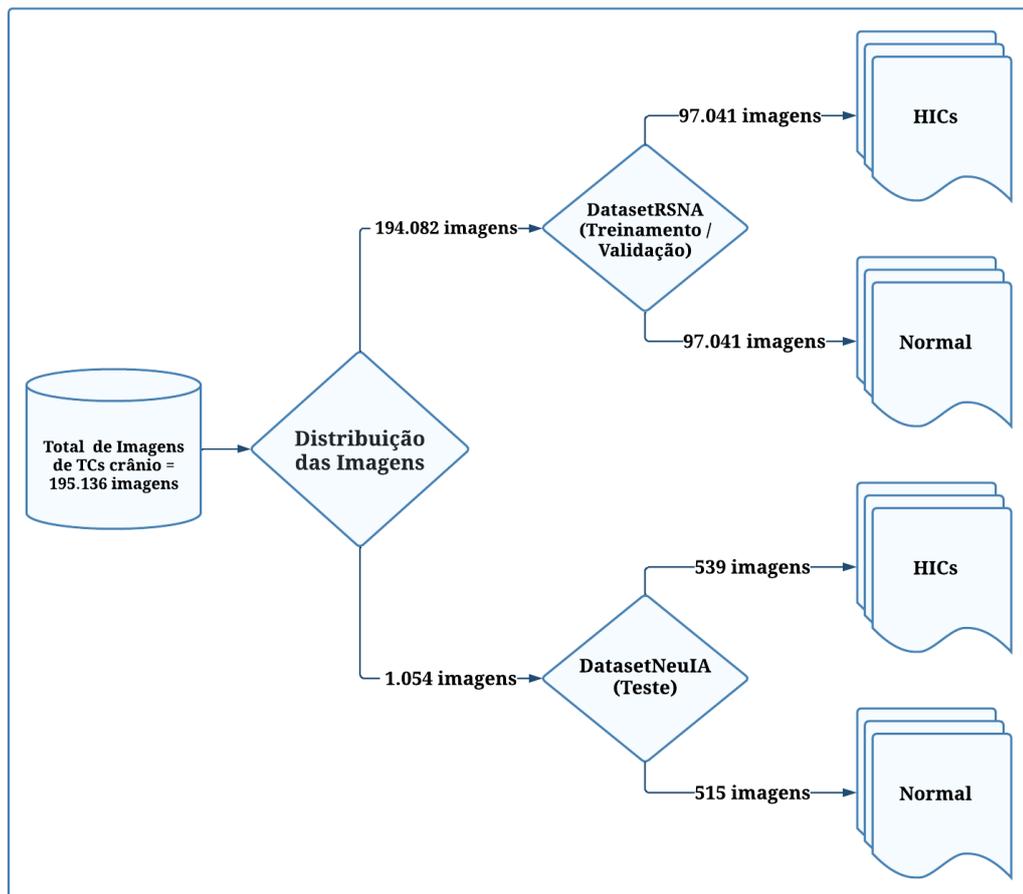
Requisitos de segurança como anonimização das imagens, acessos individuais com senhas, criptografias, *softwares* antivírus atualizados e *checklist* para estudos em imagem usando IA, foram respeitados conforme a Lei Geral de Proteção de Dados Pessoais (LGPD) (PATARRA, 2020) e os Consensos *SPIRIT-AI* (RIVERA *et al.*, 2018), *CONSORT-AI* (IBRAHIM *et al.*, 2021) e *CLAIM* (MONGAN; MOY; KAHN, 2020). Os *datasets* ficaram sob guarda do LBAM e poderão ser utilizados para pesquisas futuras com autorizações das comissões de éticas pertinentes.

Para realização do estudo foram empregadas, portanto, 195.136 imagens de TCs de crânio. Destas, 194.082 imagens eram pertencentes ao *dataset RSNA* (conjunto de treinamento) e 1054 imagens eram advindas do *dataset* construído pelos autores (*dataset NeuIA*), construído com base em casos neurocirúrgicos locais (conjunto de teste).

Para a construção do *dataset NeuIA* foram selecionadas imagens com graus variáveis de dificuldade de classificação, foram utilizadas imagens contendo desde discretos achados de Hemorragias Subaracnóideas Traumáticas à grandes Hematomas Intracranianos Epidurais e Subdurais. Os pacientes selecionados apresentavam 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 (49%, 515 imagens normais) e Subdataset *NeuIA* HICs (51%, 539 imagens com HICs), conforme podemos observar na Figura 11.

Figura 11 - Origem e Notação dos datasets.

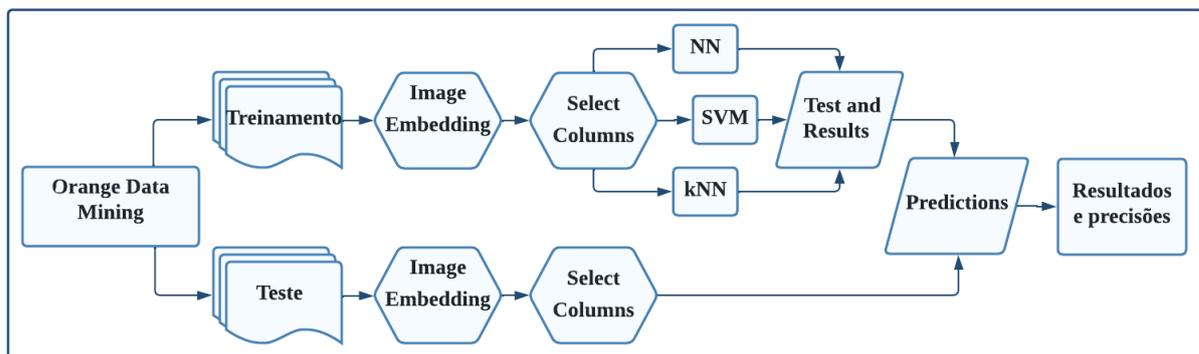


Fonte: próprio autor.

2.2 Workflow e Orange Data Mining (ODM)

Para o processamento foi utilizado o software Orange®, que não necessita da digitação de códigos de comando. O programa possui uma interface simples, contém ícones de programação rápida e ferramentas de visualização e manipulação de dados que foram utilizadas para a realização do trabalho. No *software*, portanto, foi desenvolvido um *workflow* onde cada um dos conjuntos foi ligado, respectivamente, aos *widgets* “Image Embedding” e “Select Columns” para o pré-processamento dos dados. Em seguida, o conjunto de treinamento foi submetido aos classificadores disponíveis na plataforma, como “Neural Network”, “Support Vector Machine (SVM)” e “kNN (k-nearest neighbors)”. Cada modelo foi ligado ao *widget* “Test and Score” para posterior comparação de precisão entre eles e, através do *widget* “Predictions”, os conjuntos foram comparados para validação do treinamento (Figura 12).

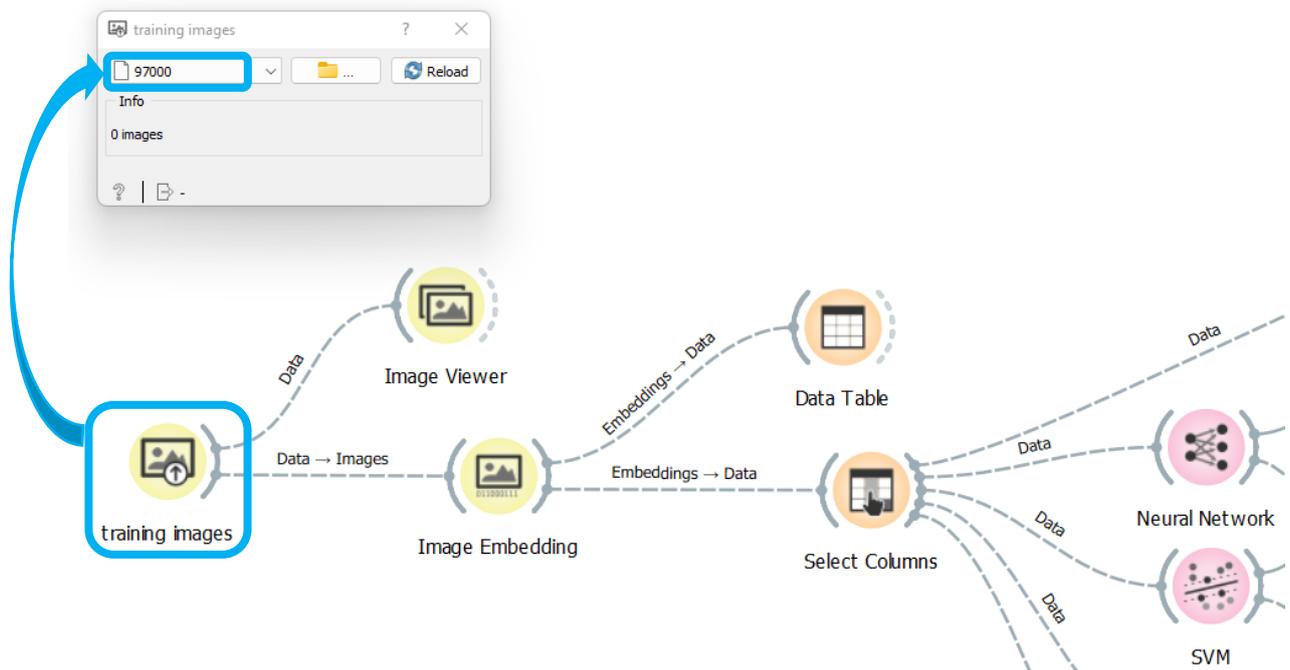
Figura 12 - Estrutura proposta para o workflow.



Fonte: próprio autor.

Inicialmente, através do *widget Import Images* foi realizado o carregamento do *dataset* RNSA no Orange para a etapa de Treinamento e Validação (Subdatasets HICs e Normal), conforme mostrado na Figura 11.

Figura 13 - Fluxo do processamento de dados no algoritmo: Importação das Imagens.

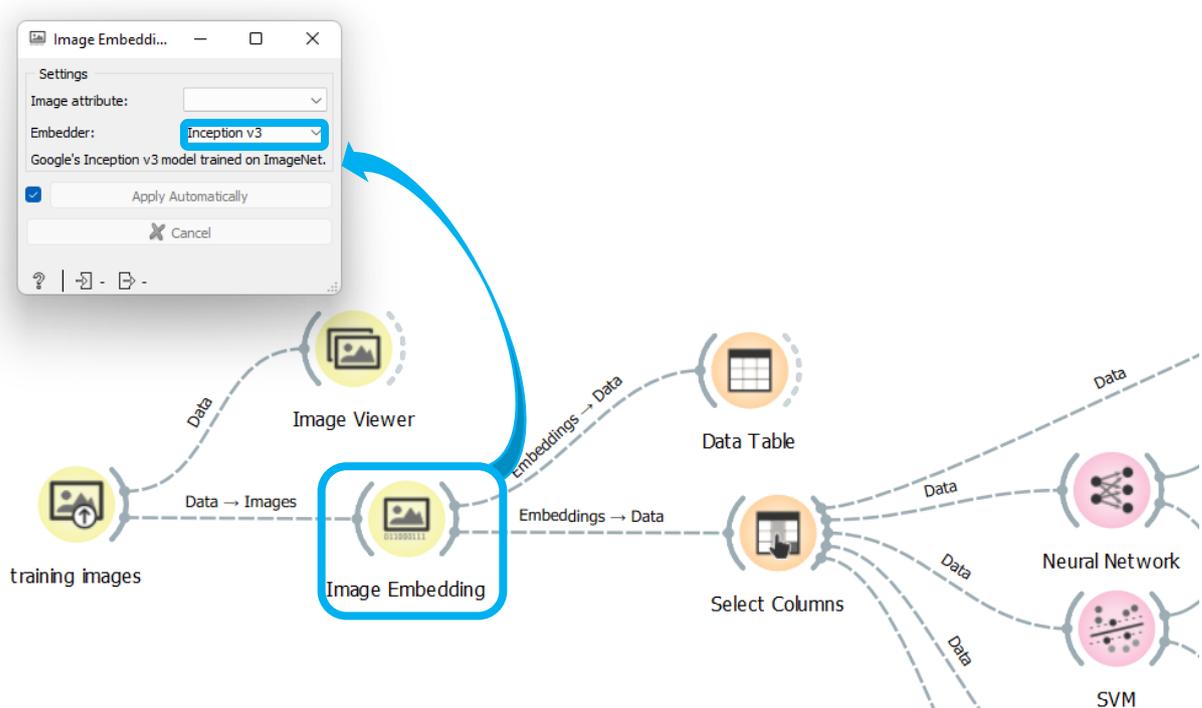


Fonte: próprio autor.

Após a adição dos dados de entrada (*inputs*) no workflow, para o processamento na etapa seguinte foi adicionado o *widget Image Embedding* (Incorporação de Imagens). Essa ferramenta é responsável por enviar as imagens a servidores (hospedados tanto *on-line* quanto *off-line*) que permitem seu processamento por modelos e transformam as imagens (*inputs*) em representações numerais ou vetoriais (*outputs*).

O *widget Image Embedding* oferece vários tipos de Incorporadores (*Embedders*). Esses modelos podem ser utilizados para a intercambialidade de análises e regulação do algoritmo. São exemplos de Incorporadores o *Inception V3* e o *Inception V4*, ambos utilizados remotamente (*on-line*) e o *SqueezeNet*, por exemplo, seria um exemplo de servidor local (*off-line*). No trabalho, foi utilizado o *Inception V3* voltado à classificação de imagens e detecção de objetos, conforme mostrado na Figura 12.

Figura 14 - Fluxo do processamento de dados no algoritmo: Incorporação de Imagens.

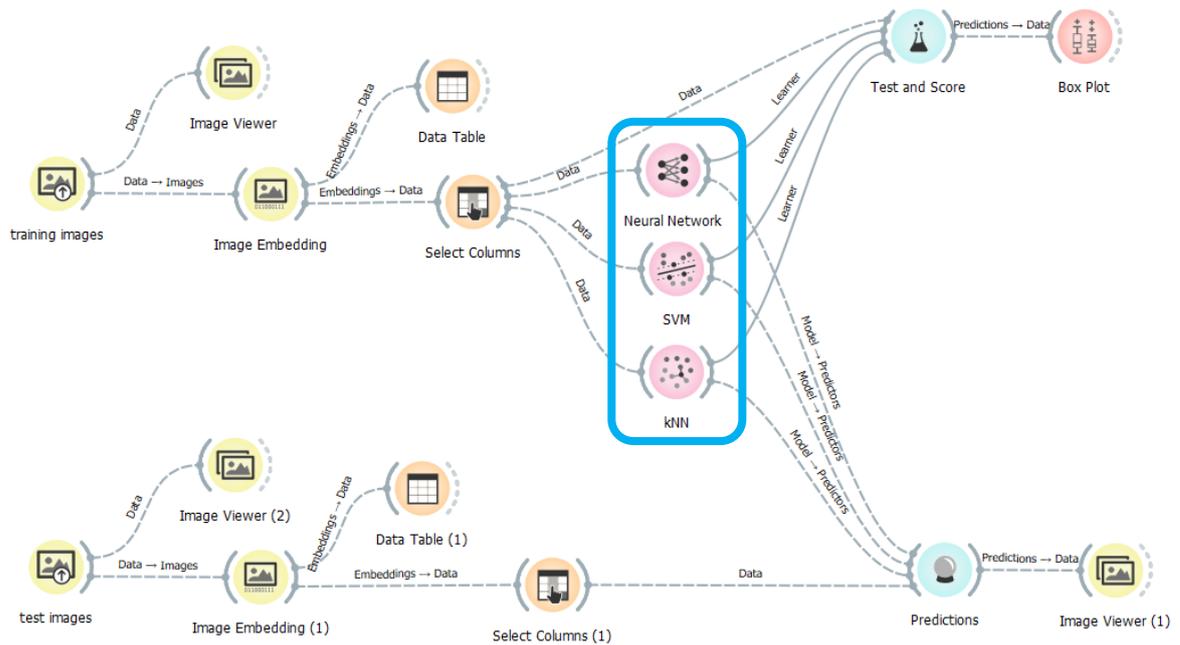


Fonte: próprio autor.

Estes novos dados, agora vetorizados e tabelados, são os dados de entrada (*inputs*) do *widget* seguinte, o *Select Columns* (Seleção de Colunas). Essa função é responsável por selecionar manualmente os atributos a serem estudados. Existem vários tipos de atributos que poderiam ser estudados como os atributos simples, os de classe e os meta atributos. Porém para a realização do trabalho, optou-se pela seleção de atributos simples e de classe discretos, que são mais adequados a tarefa de classificação de imagens.

Novamente, os atributos selecionados pelo programa foram direcionados como dados de entrada (*inputs*) para análise e comparação de resultados por quatro modelos classificadores de *Machine Learning*: *Artificial Neural Network* (ANN), *Support Vector Machine* (SVM) e *k-Nearest-Neighbours* (k-NN), mostrados na Figura 13.

Figura 15 - Fluxo do processamento de dados no algoritmo: Modelos de *Machine Learning*.



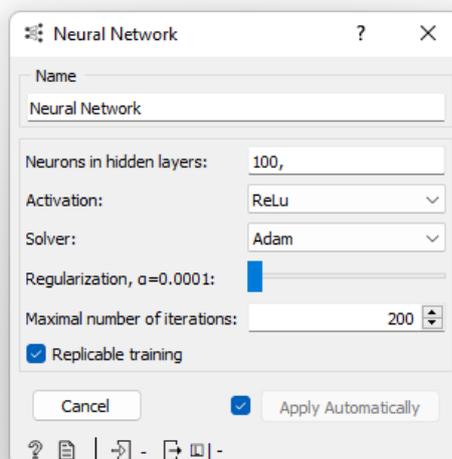
Fonte: próprio autor.

2.3 Modelos de Classificação

2.3.1 Redes Neurais Artificiais (ANN)

O widget ANN usa o algoritmo *Multi-layer Perceptron* do *scikit-learn* que pode aprender tanto modelos não lineares quanto lineares (ORANGE, 2022). Para este classificador foram utilizados 100 Neurônios por camada oculta, a função de ativação utilizada foi do tipo “ReLU” (função de unidade linear retificada) e o otimizador empregado foi o “Adam” que realiza a otimização se baseando em gradiente estocástico (Figura 16).

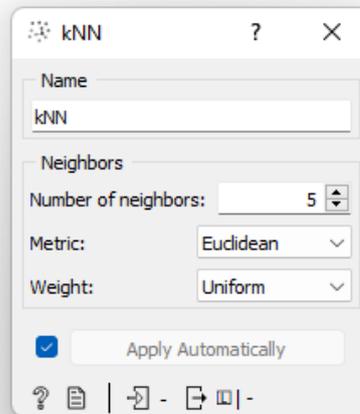
Figura 16 - Fluxo do processamento de dados no algoritmo: Redes Neurais Artificiais.



Fonte: próprio autor.

2.3.2 K- Nearest Neighbors (kNN)

O *widget* kNN procura k exemplos de treinamento mais próximos no espaço de recursos e usa sua média como previsão (ORANGE, 2022). Foi utilizada a métrica euclidiana (“linha reta”, cálculo da distância entre dois pontos), o peso foi definido como Uniforme (todos os pontos em cada vizinhança são ponderados igualmente) e o número de vizinhos como 5 (Figura 17).

Figura 17 - Fluxo do processamento de dados no algoritmo: K- *Nearest Neighbors*.

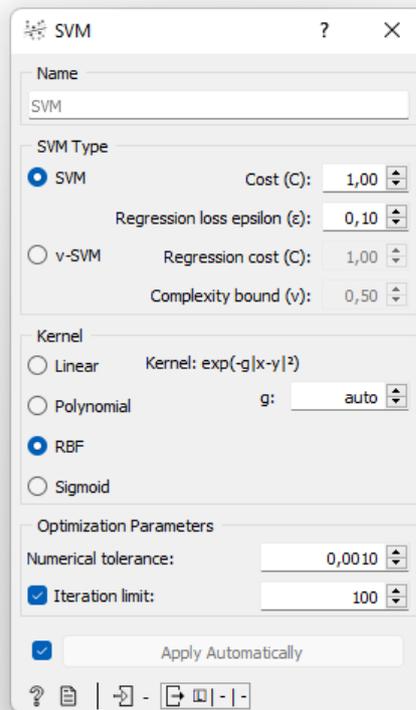
Fonte: próprio autor.

2.3.3 Support Vector Machines (SVMs)

O SVM é uma técnica de aprendizado de máquina que separa o espaço de atributos com um hiperplano, maximizando assim a margem entre as instâncias de diferentes classes ou valores de classe. A técnica geralmente produz resultados de desempenho preditivos supremos. Orange incorpora uma implementação popular de SVM do pacote LIBSVM (ORANGE, 2022).

Para este modelo, o *Cost* (prazo de penalidade por perda) foi definido como 1 e o *épsilon* (define a distância dos valores verdadeiros dentro dos quais nenhuma penalidade está associada aos valores previstos) foi definido com 0,1. O Kernel utilizado no modelo SVM foi o RBF (*Radial Basis Function Kernel*) comumente aplicado em classificadores SVM. Por fim, nos parâmetros de otimização, o desvio permitido do valor esperado foi de 0,001 e o número máximo de iterações permitidas foi de 100 (Figura 18).

Figura 18 - Fluxo do processamento de dados no algoritmo: *Support Vector Machines*.



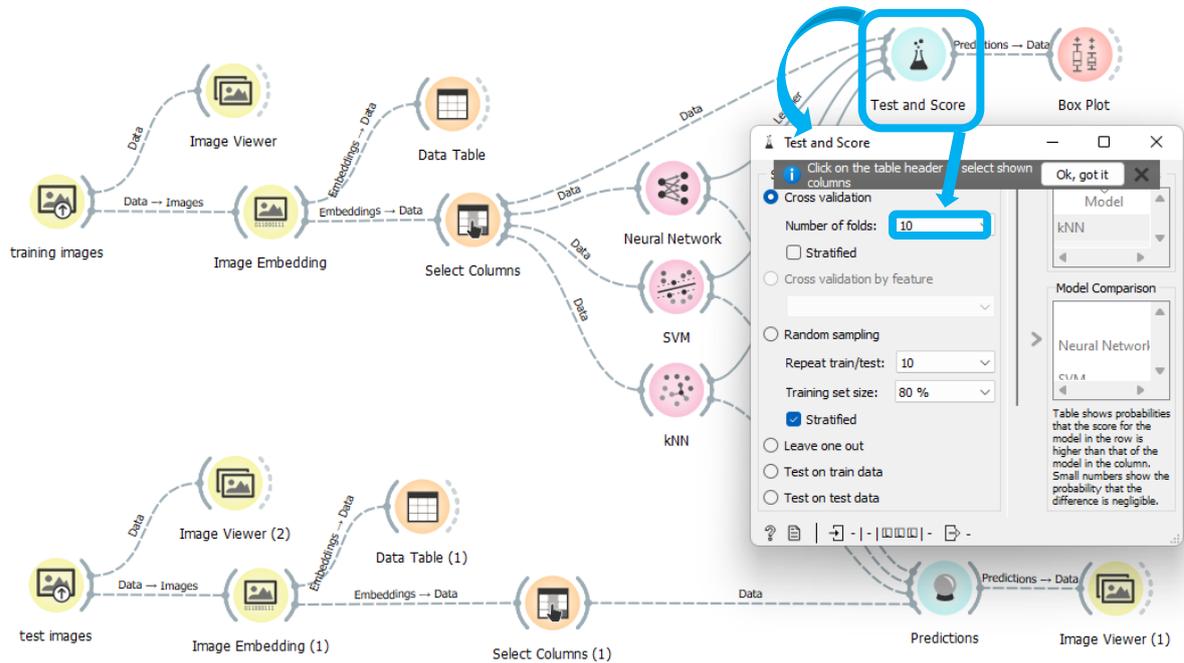
Fonte: próprio autor.

2.4 Teste e validação dos modelos de classificação

Os *outputs* de todos os modelos foram analisados separadamente pelo *widget* “*Test and Score*”. Essa função é responsável por demonstrar os diferentes desempenhos dos modelos classificadores utilizados durante o treinamento, medindo-se sua performance estatística através das seguintes métricas: Área Sob a Curva ROC, Acurácia, *F1*, *Recall* e Precisão.

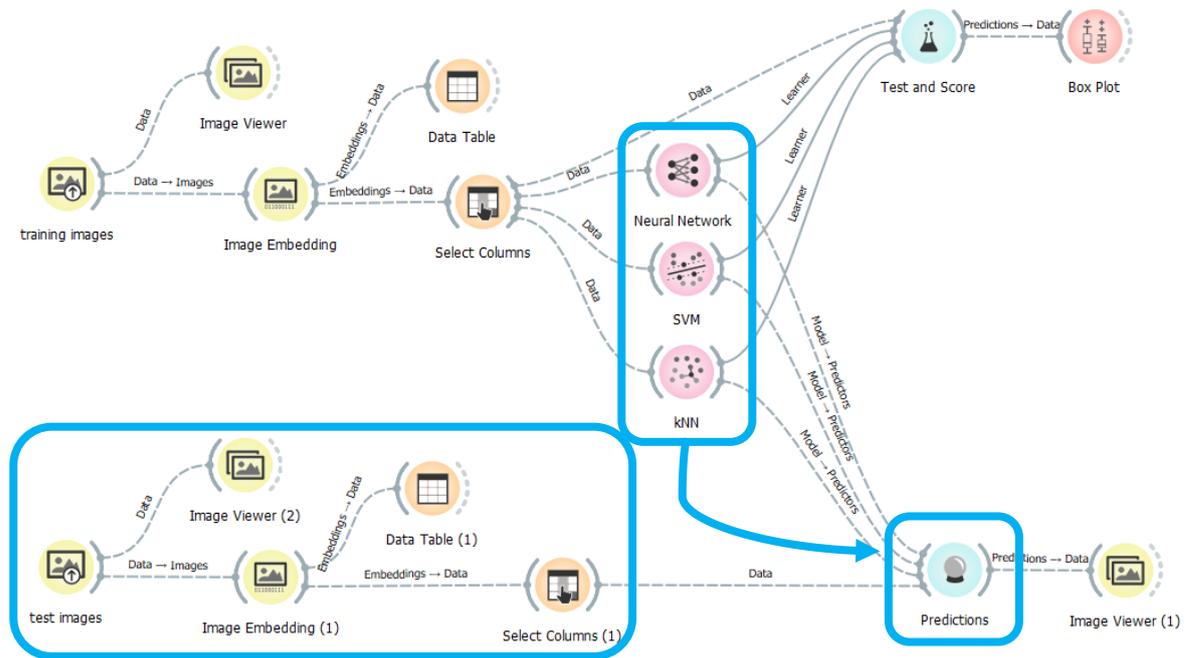
Para a validação dos classificadores foi utilizado o método de *Cross Validation*, este método é responsável por dividir os dados dos *datasets* de Treinamento HIC e Normal em subdatasets, comparando-os entre si, o que possibilita a Validação das classificações. Foi utilizada o *Cross Validation* de 10 *Folds* (dobras), onde os *datasets* treinados foram divididos em 10 grupos e cada subgrupo foi comparado entre si, como observado na Figura 19.

Figura 19 - Fluxo do processamento de dados no algoritmo: Test and Score.



Fonte: próprio autor.

Após realizadas as etapas de Treinamento e Validação, na parte inferior do *workflow*, foram introduzidas as imagens correspondentes ao *dataset NeuIA* utilizadas para a testagem dos modelos. As imagens deste *dataset* eram inéditas aos classificadores treinados, a fim de se averiguar a performance estatística da análise frente a uma tarefa classificatória nova e com dados locais. A estrutura desenvolvida para os testes é similar a etapa de Treinamento e Validação, porém o *widget Select Columns* agora foi ligado diretamente ao *Predictions* que também recebeu os resultados dos classificadores (Figura 18) a fim de realizar a comparação das probabilidades e decisões finais dos modelos preditivos aplicadas as imagens do *dataset* de teste.

Figura 20 - Fluxo do processamento de dados no algoritmo: *Predictions*.

Fonte: próprio autor.

3 RESULTADOS

Após a etapa de Treinamento e Validação (*dataset* RSNA com 194.082 imagens), foram obtidos índices de classificação satisfatórios em dois modelos dos três empregados, os valores podem ser observados na Tabela 1.

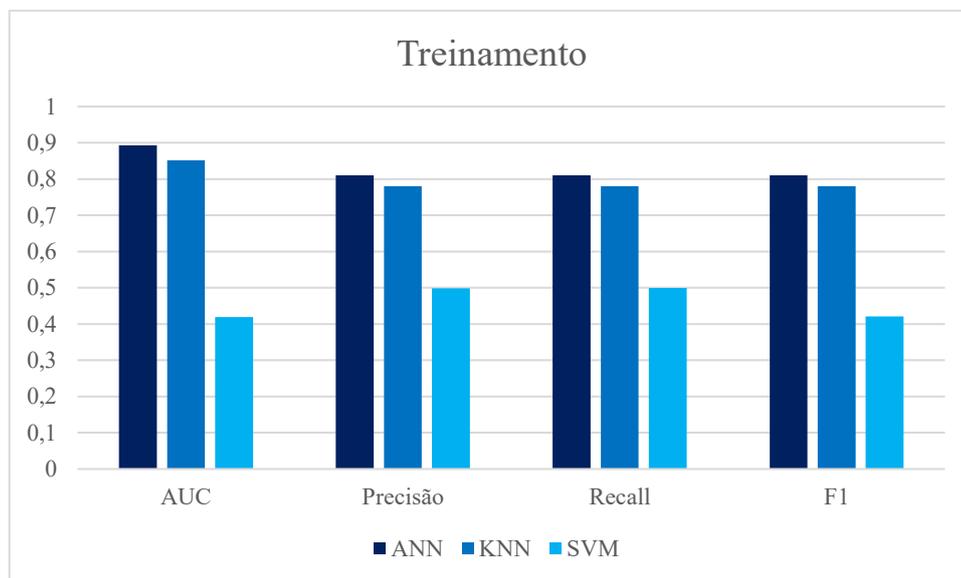
TABELA 1 - Resultados obtidos na etapa de Treinamento.

Modelos	AUC	F1	Precisão	Recall
ANN	0.893	0.81	0.81	0.81
KNN	0.852	0.78	0.78	0.78
SVM	0.419	0.421	0.498	0.499

Fonte: próprio autor.

O modelo *Artificial Neural Networks* (ANN), utilizando o *Crossvalidation* de 10 *folds*, obteve os resultados mais satisfatórios de classificação, com baixos índices de erro (AUC= 0.893, Precisão= 0.81, Recall = 0,81, F1 = 0.81). Achados menos precisos foram encontrados no modelo k-NN (AUC = 0.852, CA= 0.780, F1 score = 0.700, Precisão= 0,780 e Recall = 0,780) e os valores obtido pelo modelo SVM foram consideravelmente inferiores (AUC = 0.419, CA = 0.499, Precisão = 0.421 e Recall 0.410), esses dados podem ser visualizados graficamente através da figura 21.

Figura 21 - Resultados obtidos na etapa de Treinamento.



Fonte: próprio autor.

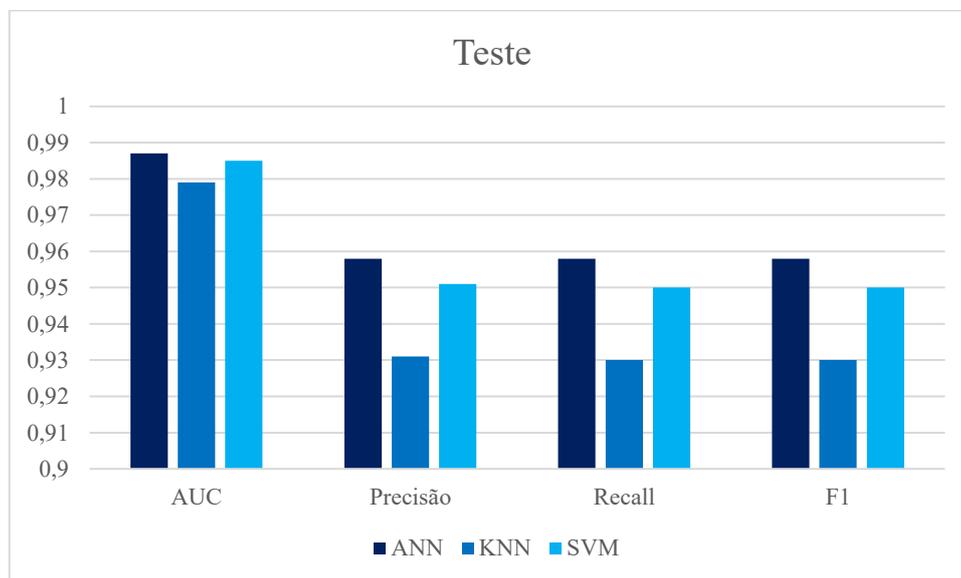
Após realizar a etapa de Treinamento e Validação, foi iniciada a etapa de Teste com o uso do *dataset* NeuIA. O resultado da análise foi satisfatório, com índices de acertos também superiores no modelo *Neural Network* (AUC = 0.987, F1= 0.930, Precision=0.931 e Recall = 0.930), mas com os demais modelos apresentando valores muito próximos (Figura 22).

TABELA 2 - Resultados obtidos na etapa Teste.

Modelos	AUC	F1	Precisão	Recall
ANN	0.987	0.958	0.958	0.958
KNN	0.979	0.93	0.931	0.93
SVM	0.985	0.95	0.951	0.95

Fonte: próprio autor.

Figura 22 - Resultados obtidos na etapa Teste.



Fonte: próprio autor.

4 DISCUSSÃO

No presente estudo, esperava-se avaliar o desempenho dos algoritmos de Aprendizado de Máquina, presentes na plataforma Orange, na classificação de HICs em TCs. Inicialmente, foi observado uma diferença significativa de performance na etapa de treinamento entre os modelos. ANN e KNN apresentaram resultados satisfatórios, enquanto que o modelo SVM demonstrou valores muito baixos de performance. Ao analisar a figura 19 foi possível observar que na etapa treinamento, onde se empregou o *dataset RNSA* de maior robustez, o modelo SVM apresentou maior quantidade de erros, se comparado aos demais algoritmos, seus resultados

foram consideravelmente inferiores aos demais classificadores em todas as variáveis analisadas (valores). Este fato era esperado, de certa forma, por se tratar de um modelo que apresenta uma arquitetura mais simples que os demais.

Em relação as métricas analisadas, a área sob a curva (AUC), fornece uma medida agregada de desempenho em todos os limites de classificação possíveis dos modelos (MACHINE, 2022). Neste estudo, os valores de AUC obtidos, ao final da etapa de treinamento, foram bem condizentes com o esperado, as previsões dos modelos ANN e KNN demonstraram estar corretas em 89 e 85 % das vezes, respectivamente (AUC = 0,893 para ANN e AUC = 0,852 para KNN).

Assim como a AUC, a precisão é uma métrica muito utilizada na avaliação de modelos de classificação, ela representa a fração de previsões que o algoritmo foi capaz de acertar. Para a classificação binária, a precisão também pode ser calculada em termos de positivos e negativos, sendo assim, capaz de indicar qual a proporção de identificações positivas estava realmente correta. Quando se está trabalhando com um conjunto de dados desbalanceados, onde há uma disparidade significativa entre o número de rótulos positivos e negativos, a precisão pode se tornar um problema, possibilitando muitas vezes uma interpretação equivocada em relação a real assertividade dos modelos. Métricas como o *Recall*, por exemplo, são geralmente utilizadas para contornar esse problema em dados desbalanceados. O *Recall* indica qual proporção de positivos reais foi identificada corretamente (MACHINE, 2022).

A fim de evitar complicações nessas métricas, os *datasets* foram elaborados de forma balanceada, as imagens do conjunto de Treinamento já estavam distribuídas igualmente entre positivas e negativas para a incidência de HIC's (97.041 imagens para cada *subdataset*) e os dados obtidos para o conjunto de Teste (*dataset* NeuIA) apresentam distribuição similar com 49% das imagens sendo normais (515 imagens) e 51% apresentando HICs (539 imagens). Isso se mostrou bastante válido, visto que em ambas as fases (Treinamento e Teste) os valores de Precisão e Recall foram muito similares (Tabelas 1 e 2).

Nessa mesma linha, como Precisão e Recall apresentaram valores muito próximos e F1 é a média harmônica entre essas duas métricas, os valores de F1 foram similares aos obtidos nos demais. Ouve disparidade nos valores de F1 apenas no modelo SVM do conjunto de treinamento (Figura). Como o cálculo de F1 é baseado em uma média harmônica que se apresenta muito mais próxima aos menores valores do que uma média aritmética simples. O menor valor de F1 observado foi um indicativo de que a Precisão ou o Recall estavam baixos, isto fora de fato observado nos dados de Treinamento apresentados pelo modelo SVM que se mostraram insatisfatórios (Precisão = 0,498, Recall = 0,499 e AUC = 0,419).

Contudo, todos os modelos apresentaram na etapa de teste (*dataset NeuIA*) resultados muito próximos. 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*, otimizados. Não foi objetivo do estudo, portanto, otimizar individualmente os modelos e estudar quais parâmetros aumentariam a precisão de suas classificações. Devido a isso, foram utilizadas configurações padrões e, geralmente, recomendadas para cada um dos classificadores a fim de avaliar comparativamente seus desempenhos. Estudos futuros podem ter como objetivo a avaliação individual de alguns dos modelos testados, especialmente aqueles que demonstraram melhor desempenho em suas classificações, como observado nas Redes Neurais Artificiais.

Por fim, em relação aos *datasets*, o RSNA apresentava uma grande quantidade de imagens (194.082 no total), essa quantidade considerável de dados fez com que o processo de treinamento necessitasse de muitas horas de processamento, além de se mostrar inviável para computadores pessoais por requerir de grande poder computacional. Por outro lado, para a elaboração do *dataset* de Teste, foi observado um viés positivo em virtude dos critérios de inclusão e exclusão, 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*. Porém, de modo geral, a análise do experimento realizado foi positiva para o objetivo delineado.

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 e as análises estatísticas se mostraram satisfatórias. Porém, é importante citar 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 e de achados incidentais. Os tomógrafos utilizados e os centros envolvidos podem influenciar na variabilidade das

imagens e, conseqüentemente, nos resultados obtidos. Além disso, o número limitado de amostras de teste também pode ter contribuído com vieses positivos de seleção embora os dados de treinamento e teste estivessem balanceados entre o número de amostras positivas e negativas utilizadas. A utilização de anotações de *datasets* contemplando estes fatores e a aplicação de estudos multicêntricos que utilizem de hardwares de múltiplos fabricantes, podem ser uma alternativa e resolução destes problemas.

Entretanto os resultados são considerados satisfatórios, sobretudo por poder demonstrar que soluções tecnológicas baseadas em IA são exequíveis e podem ter grande impacto na saúde pública. Se incorporadas, essas técnicas poderiam acelerar a 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 como 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 com baixa infraestrutura.

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

REFERÊNCIAS

AMORIM, D. G. Redes ART com categorias internas de geometria irregular. Tese de Doutorado - **Universidade de Santiago de Compostela** - Departamento de Eletrônica e Computação, p. 112, 2007.

AZEVEDO, Y. *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**, v. 7, n. 3, p. 1106, 2016.

BARRETO, J. M. Introdução as redes neurais artificiais. **Escola Regional de Informática da SBC Regional Sul**, p. 41–71, 1997.

BELLMAN, R. E. Adaptive control processes - A guided tour. **Princeton University Press**, Princeton, New Jersey. p. 255, 1961.

BITTENCOURT, R.; HORTALE, V. Intervenções para solucionar a superlotação nos serviços de emergência hospitalar: uma revisão sistemática. **Cadernos de Saúde Pública**, v. 25, n. 7, p. 1439–1454, 2009.

CARNEY, N. *et al.* Guidelines for the Management of Severe Traumatic Brain Injury, Fourth Edition. **Neurosurgery**, v. 80, n. 1, p. 6–15, 2017.

CHOWDHURY, S.; CHAKRABORTY, P. Universal health coverage - There is more to it than meets the eye. **Journal of Family Medicine and Primary Care**, v. 6, n. 2, p. 169–170, 2017.

COHEN, A.; NAHED, V.; SHETH, N. Practice Mobile medical applications in neurology. **Neurology Clinical**. p. 52–60, 2013.

CORTES, C.; VAPNIK, V. Support-Vector Networks. **Kluwer Academic Publishers Hingham**, v. 20, p. 273–297, 1995.

DEFILLO, A. Letter to the Editor. **Journal of Neurosurgery**, v. 116, n. 1, p. 256–257, 2011. *Explorations in Artificial Intelligence and Machine Learning*. [S.l: s.n.], [S.d.].

DUONG, M. T.; RAUSCHECKER, A. M.; MOHAN, S. Diverse Applications of Artificial Intelligence in Neuroradiology. **Neuroimaging Clin N Am**, p. 30, n. 4, p. 505–16, 2020. Disponível em: <<https://doi.org/10.1016/j.nic.2020.07.003>>. Acesso em: 18 jul. 2022.

FLANDERS, A. E.; PREVEDELLO, L. M.; SHIH, G.; HALABI, S. S.; 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**, v. 2, n. 4, 2020.

GAMEIRO, G. *et al.* Inteligência Artificial a Serviço da Medicina Brasileira. **Revista de Medicina**, v. 98, n. 1, p. i–iii, 2019.

GARDNER, A. *et al.* A systematic review of diffusion tensor imaging findings in sports-related concussion. **Journal of Neurotrauma**, v. 29, n. 16, p. 2521–2538, 2012.

GODEC, P.; PANČUR, M.; ILENIČ, N.; ČOPAR, A.; STRAŽAR, M.; ERJAVEC, A.; ZUPAN, B. Democratized image analytics by visual programming through integration of deep models and small-scale machine learning. **Nature Communications**, v. 10, n. 1, 2019.

HOULTON, S. How artificial intelligence is transforming healthcare. **Prescriber**, v. 29, n. 10, p. 13–17, 2018.

IBRAHIM, H.; LIU, X.; RIVERA S. C.; MOHER, D.; CHAN, A. W.; SYDES, M. R. *et al.* Reporting guidelines for clinical trials of artificial intelligence interventions: the SPIRIT-AI and CONSORT-AI guidelines. **Trials**, v. 22, n. 1, p. 1–5, 2021.

ILEOH. O Algoritmo K-Nearest Neighbors (KNN) em Machine Learning. **Portal Data Science**, 2018. Disponível em: <<https://portaldatascience.com/o-algoritmo-k-nearest-neighbors-knn-em-machine-learning/>>. Acesso em: 18 jul. 2022.

KAUL, V.; ENSLIN, S.; GROSS S. A. History of artificial intelligence in medicine. **Gastrointest Endosc**, v. 92, n. 4, p. 807–12, 2020. Disponível em: <<https://doi.org/10.1016/j.gie.2020.06.040>>. Acesso em: 22 jul. 2022.

KOVACS, Z. L. Redes Neurais Artificiais: Fundamentos e Aplicações. **Collegium Cognitio**, 1997. 2a. edição, São Paulo/Brasil. p. 174.

LUZ, F. Algoritmo KNN para classificação. **Inferir**, 2019. Disponível em: <<https://inferir.com.br/artigos/algoritmo-knn-para-classificacao/>>. Acesso em: 18 jul. 2022.

MACHINE Learning Concepts: Classification. **Google Developers**, 2022. Disponível em: <<https://developers.google.com/machine-learning/crash-course/classification/>>. Acesso em: 20 jul. 2022.

MARIANI, A.; PÊGO-FERNANDES, P. Telemedicina: Uma revolução tecnológica. **Sao Paulo Medical Journal**, v. 130, n. 5, p. 277–278, 2012.

MATOS, D. O Kaggle é Realmente Válido Para Aprender Data Science? **Ciência e dados – Data Science For Professionals**, 23 de out. de 2020. Disponível em: <<https://www.cienciaedados.com/o-kaggle-e-realmente-valido-para-aprender-data-science/>>. Acesso em: 17 jan. 2022.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous. **In Bulletin of Mathematical Biophysics**, v. 5, p. 115–133, 1943.

MONTEIRO, M.; NEWCOMBE, V. F.; 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**, v. 2, n. 6, p. 314–22, 2020. Disponível em: <[http://dx.doi.org/10.1016/S2589-7500\(20\)30085-6](http://dx.doi.org/10.1016/S2589-7500(20)30085-6)>. Acesso em: 17 jul. 2022.

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

NAVIANI, A. Support Vector Machines with Scikit-learn Tutorial. **Datacamp**, 2019. Disponível em: <<https://www.datacamp.com/tutorial/svm-classification-scikit-learn-python>>. Acesso em: 22 jul. 2022.

ORANGE. **Orange Data Mining**, 2022. Disponível em: <<https://orangedatamining.com/>>. Acesso em: 22 jul. 2022.

PALMIERE, S. E. Arquiteturas e Topologias de Redes Neurais Artificiais. **Embarcados**, 2016. Disponível em: <<https://embarcados.com.br/redes-neurais-artificiais/>>. Acesso em: 18 jul. 2022.

PATARRA, A. B. ToS - Termos de Uso - Lei Geral de Proteção de dados, 2020.

RAMESH, A. N. *et al.* Artificial intelligence in medicine. **Annals of the Royal College of Surgeons of England**, v. 86, n. 5, p. 334–338, 2004.

RIVERA, A. *et al.* Guidelines for clinical trial protocols for interventions involving artificial intelligence: the SPIRIT-AI extension. **Nature Medicine**, v. 26, n. 9, p. 1351–1363, 2020.

RODRIGUES, M. *et al.* Epidemiologia de traumatismo craneencefálico em um hospital TT - Epidemiology of cranioccephalic trauma in a hospital. **Rev. Soc. Bras. Clín. Méd.**, v. 16, n. 1, p. 21–24, 2018.

RSNA Intracranial Hemorrhage Detection. **Kaggle**, 2019. Disponível em:

<<https://www.kaggle.com/c/rsna-intracranial-hemorrhage-detection/overview>>. Acesso em: 10 jan. 2022.

SANTIAGO, J. Custo do Serviço de Ressonância Magnética nas entidades hospitalares: Um estudo comparativo no Hospitais da UnB e da UFRN. p. 154, 2007.

SILVA, A. H. C.; LACERDA W. S.; SILVA, B. A. Comparação de desempenho entre Máquina de Vetor de Suporte e Comitê de Redes Neurais Artificiais para Classificação de Spam. **Revista Eletrônica De Iniciação Científica Em Computação**, 2017. Disponível em: <<https://sol.sbc.org.br/journals/index.php/reic/article/view/1032>>. Acesso em: 18 jul. 2022.

SILVA, D. Entenda a diferença entre Inteligência Artificial, Machine Learning e Deep Learning. **Zendesk**, 2021. Disponível em: <<https://www.zendesk.com.br/blog/diferenca-entre-inteligencia-artificial-machine-learning-e-deep-learning/>>. Acesso em: 22 jul. 2022.

VAPNIK, V. The nature of statistical learning theory. **Springer-Verlag New York Inc**, p. 333, 1995.