UNIVERSIDADE FEDERAL DO PARANÁ

PAULO RICARDO GONÇALVES

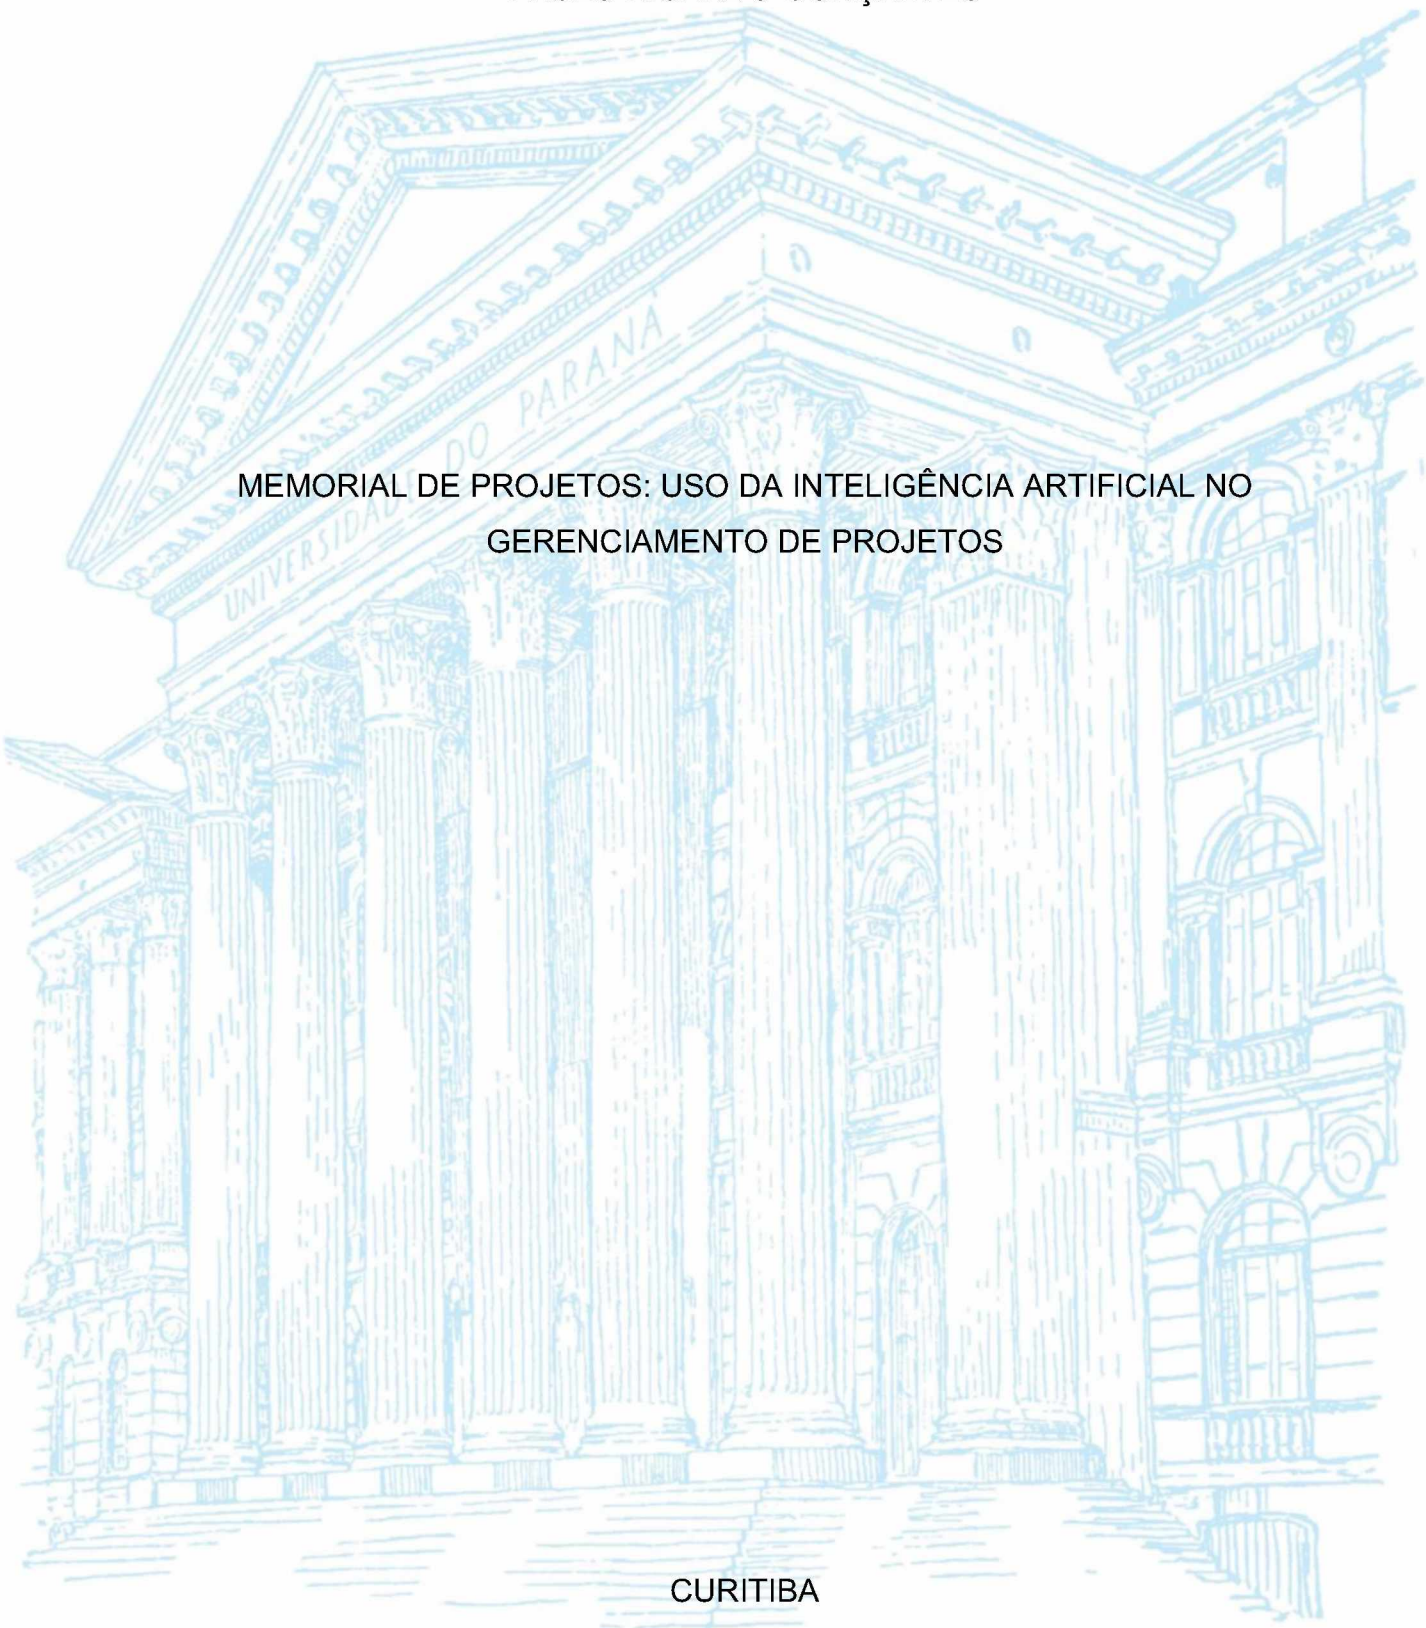

MEMORIAL DE PROJETOS: USO DA INTELIGÊNCIA ARTIFICIAL NO GERENCIAMENTO DE PROJETOS

CURITIBA

2025

PAULO RICARDO GONÇALVES

MEMORIAL DE PROJETOS: USO DA INTELIGÊNCIA ARTIFICIAL NO GERENCIAMENTO DE PROJETOS

Memorial de Projetos apresentado ao curso de Especialização em Inteligência Artificial Aplicada, Setor de Educação Profissional e Tecnológica, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Especialista em Inteligência Artificial Aplicada.

Orientador: Prof. Dr. Jaime Wojciechowski

CURITIBA

2025

MINISTÉRIO DA EDUCAÇÃO
SETOR DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA
UNIVERSIDADE FEDERAL DO PARANÁ
PRÓ-REITORIA DE PÓS-GRADUAÇÃO
CURSO DE PÓS-GRADUAÇÃO INTELIGÊNCIA ARTIFICIAL APLICADA - 40001016399E1

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação Inteligência Artificial Aplicada da Universidade Federal do Paraná foram convocados para realizar a arguição da Monografia de Especialização de **PAULO RICARDO GONÇALVES**, intitulada: **MEMORIAL DE PROJETOS: USO DA INTELIGÊNCIA ARTIFICIAL NO GERENCIAMENTO DE PROJETOS**, que após terem inquirido o aluno e realizada a avaliação do trabalho, são de parecer pela sua **aprovação** no rito de defesa.

A outorga do título de especialista está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

Curitiba, 22 de Outubro de 2025.

JAIME WOJCIECHOWSKI
Presidente da Banca Examinadora

RAFAELA MANTOVANI FONTANA
Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

RESUMO

O crescimento exponencial das tecnologias tem trazido desafios significativos às organizações e a sociedade em geral. A inteligência artificial, em especial, que antes era utilizada de modo limitado em algumas áreas hoje é utilizada quase que em todos os segmentos, seja na facilitação de tarefas repetitivas e até mesmo em algumas tarefas domésticas, como na análise e diagnóstico de cenários complexos. Esta evolução tem tornado as empresas ainda mais competitivas, obrigando-as a adaptar-se rapidamente às mudanças impostas. Neste cenário, o gerenciamento de projetos torna-se ainda mais fundamental para execução das estratégias obrigando as instituições a romper com o modo como projetos eram conduzidos no passado para uma nova forma de gestão com uso de ferramentas cada vez mais inteligentes. Não se trata da substituição do conhecimento humano pela adoção de tecnologias, mas, sim, de aplicar ferramentas de inteligência para melhor apoiar na gestão de projetos como meio de garantir a obtenção de melhores resultados. Cabe ressaltar, que a aplicação de ferramentas de inteligência artificial no apoio à gestão de projetos precisa ser cautelosa para garantir o respeito aos preceitos éticos a aos direitos humanos.

Palavras-chave: agentes de IA; ferramentas de IA; gerenciamento de projetos; inteligência artificial; projetos.

ABSTRACT

The exponential growth of technology has introduced significant challenges to organizations and society at large. Artificial intelligence, in particular, which was previously applied in a limited capacity within select domains, is now utilized across nearly all sectors—from automating repetitive tasks and assisting with household activities to analyzing and diagnosing complex scenarios. This evolution has heightened competitiveness among companies, compelling them to rapidly adapt to emerging changes. In this context, project management becomes increasingly vital for the execution of strategic initiatives, requiring institutions to move beyond traditional approaches and adopt new management models supported by increasingly intelligent tools. This shift does not imply the replacement of human expertise with technology; rather, it emphasizes the integration of intelligent systems to enhance project management and improve outcomes. It is important to underscore that the application of artificial intelligence tools in project management must be approached with caution to ensure adherence to ethical principles and the protection of human rights.

Keywords: AI agents; AI tools; project management; artificial intelligence; projects.

SUMÁRIO

1 PARECER TÉCNICO

O uso da inteligência artificial em nossas tarefas diárias seja na vida pessoal como na profissional já não pode mais ser evitado. Se antes sua utilização mais perceptível era na recomendação de itens de consumo em poderosos sites da internet, hoje a utilizamos quase que em todas as tarefas que fazem o uso de algum dispositivo tecnológico. No ambiente de projetos não é diferente; ferramentas de inteligência artificial passam a ser utilizadas desde a melhoria de processos, no apoio a tomada de decisão, ou na otimização das entregas de projetos, dentre várias outras aplicações (Stachowiak, 2025). Um projeto é um esforço temporário empreendido para criar um produto, serviço ou resultado único. Já o gerenciamento de projetos é a aplicação de conhecimentos, habilidades, ferramentas e técnicas às atividades do projeto para cumprir os requisitos definidos; refere-se a orientar o trabalho do projeto para entregar os resultados pretendidos. O gerente de projeto, por sua vez, é a pessoa designada pela organização executora para liderar a equipe do projeto, sendo o responsável por alcançar os objetivos definidos (PMI, 2021). Em meio a isso, e sendo a inteligência artificial um campo na área da ciência da computação que nos traz milhares de ferramentas capazes de simular a capacidade humana, o seu uso através de suas mais diversas ferramentas no gerenciamento de projetos vem a contribuir em diversas frentes de trabalho nos mais diversos tipos de projetos (Alshaikhi, 2021).

Dentre as aplicações da inteligência artificial na gestão de projetos destacam-se, mas não se limitam a estas, a seleção e priorização de projetos, o suporte a escritórios de projetos, maior velocidade na definição, planejamento, apresentação de relatórios, uso de assistentes virtuais, testes avançados de sistemas e softwares, atuação em tarefas repetitivas, permitindo a gerentes de projetos atuar na liderança de suas equipes (Rodriguez, 2023). Adicionalmente, ferramentas de IA podem ser utilizadas para apoiar gerentes de projetos na elaboração de planos de projeto, cronogramas, alocação de equipe ou na análise de riscos, além de serem cada vez mais utilizadas no apoio na tomada de decisão, análise de custos, recuperação de desvios, e incrementando eficiência nas comunicações (Alshaikhi, 2021).

A FIGURA 1, a seguir, traz alguns exemplos de ferramentas de IA e sua aplicação durante parte do ciclo de vida de um projeto:

FIGURA 1 – Como Utilizar IA na Gestão de Projetos?

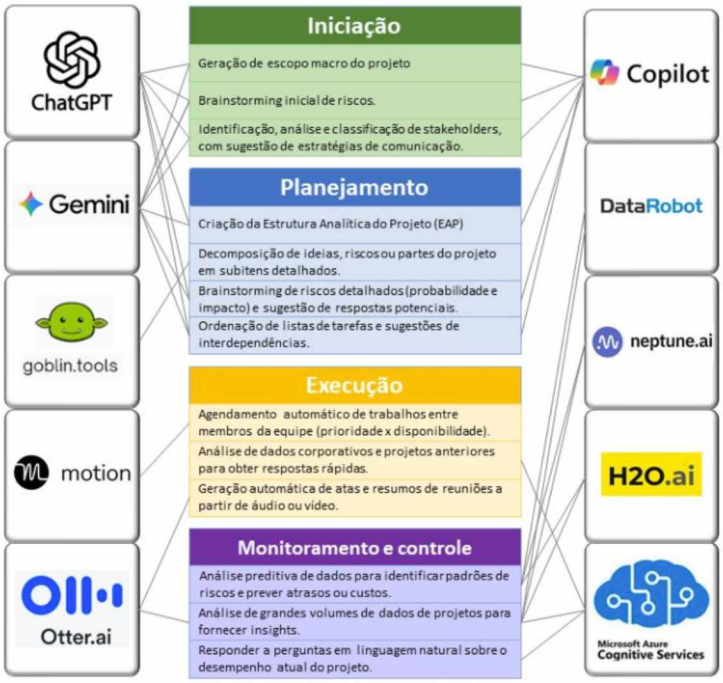

FONTE: Costa (2025)

Especialmente no apoio a tomada de decisões, o uso da IA resulta em grandes benefícios aos projetos por possuirem a capacidade de análise de grandes quantidades de dados e de variáveis com o uso de LLM – Large Language Model, assim como nas comunicações do projeto por meio do uso de chatbots dotados de NLP – Natural Language Processing, ou processamento de linguagem natural (Vargas, 2025). Adicionalmente, uma tendência crescente é o uso de agentes virtuais nas diferentes fases do ciclo de vida de projetos. Os agentes são capazes de predizer riscos sugerindo ações de resposta, alocação da equipe do projeto considerando a diversidade cultural, criação de metodologias especialmente desenhadas para um objetivo específico, e têm a capacidade de tomada de decisão e execução de tarefas de modo automático, sem intervenção humana, conforme a necessidade do projeto (Vargas, 2025).

No entanto, a adoção de ferramentas de inteligência artifical pelas organizações revela alguns desafios a serem superados. A qualidade dos dados disponíveis para treinamento dos modelos de inteligência, questões legais em relação ao uso de dados pessoais ou de sigilo corporativo, questões éticas ou vieses (biases) gerados em respostas, desenvolvimento de pessoal para correto uso da tecnologia, receio das pessoas quanto a substituição do conhecimento humano por máquinas,

constituem alguns destes desafios (Zia, 2024). As ações de adaptação nem sempre são simples e requerem uma cultura aberta à inovação. A substituição de práticas tradicionais de gerenciamento de projetos pelo uso de ferramentas de IA exige investimento em capacitação, resiliência, tolerância a falhas durante fase de adoção, e apoio da alta gestão (Rodriguez, 2023).

TABELA 1 – Benefícios da Adoção da IA no Gerenciamento de Projetos

Benefícios	Percentual de Respondentes (%)
Automação de tarefas rotineiras	72
Capacidade aprimorada de tomada de decisão	84
Otimização da alocação de recursos	68
Melhoria nos resultados do projeto	76
Percepções preditivas para gestão de riscos	62

FONTE: Adaptado de Zia, M et al. (2024)

TABELA 2 – Desafios da Adoção da IA no Gerenciamento de Projetos

Benefícios	Percentual de Respondentes (%)
Preocupações com privacidade de dados	48
Vieses algorítmicos	56
Implicações éticas	52
Resistencia organizacional	60
Lacunas de habilidades na equipe do projeto	64

FONTE: Adaptado de Zia, M et al. (2024)

As TABELAS 1 e 2, acima, trazem, respectivamente, os resultados de recente pesquisa a cerca dos benefícios e desafios da adoção da IA no gerenciamento de projetos reforçando quanto a importância de seu uso no apoio à tomada de decisões e ratifica a falta de skill entre membros do time de projetos como um dos principais desafios às organizações (Zia, 2024). À medida que novas ferramentas de IA são desenvolvidas e as equipes de projeto se especializam em seu uso uma nova forma de gestão de projetos se molda possibilitando aos gerentes de projetos atuarem com maior ênfase na liderança dos times e na comunicação com principais stakeholders enquanto tarefas repetitivas ou voltados à análise de dados sejam executadas por agentes ou ferramentas especiais de inteligência artificial (Alshaikhi, 2021). A inteligência artificial por meio de suas ferramentas vem suportar gerentes e times de projetos e não para substituí-los.

REFERÊNCIAS

ALSHAIKHI, A.; KHAYYAT, M. **An investigation into the Impact of Artificial Intelligence on the Future of Project Management**, 2021. Disponível em: https://doi.org/10.1109/WiDSTaif52235.2021.9430234. Acesso em: 28 set. 2025.

COSTA, F. **IA Generativa aplicada à Gestão de Projetos: otimização de tarefas e potencialização da governança.** LinkedIn, 16 set. 2025. Disponível em: https://www.linkedin.com/posts/fabiocostapmp_gestaodeprojetos-inteligenciaartificial-activity-7373489939923161088-6YfV/?originalSubdomain=pt. Acesso em: 28 set. 2025.

PMI – PROJECT MANAGEMENT INSTITUTE. **Guia PMBOK®: um guia para o conjunto de conhecimentos em gerenciamento de projetos**. 7. ed. Newton Square: Project Management Institute, 2021

RODRIGUEZ, A.; VARGAS, R. How AI Will Transform Project Management. **Harvard Business Review**, 2023. Disponível em: https://hbr.org/2023/02/how-ai-will-transform-project-management. Acesso em: 28 set. 2025.

STACHOWIAK, K. **The Use of Artificial Intelligence in Project Management**, 2025. Disponível em: http://dx.doi.org/10.29119/1641-3466.2025.217.17. Acesso em: 28 set. 2025.

VARGAS, R. **Gerenciamento de Projetos com Agentes de IA** [curso on-line]. LinkedIn, 2025. Disponível em: https://www.linkedin.com/learning/revolucionando-o-gerenciamento-de-projetos-com-agentes-de-ia/gerenciamento-de-projetos-com-agentes-de-ia. Acesso em: 28 set. 2025

ZIA, M. *et al*. Role Of Artificial Intelligence in Big Database Management. **The Asian Bulletin of Big Data Management**, v. 4, n. 2, p. 186–194, 2024. DOI: 10.62019/abbdm.v4i02.164. Disponível em: https://abbdm.com/index.php/Journal/article/view/164. Acesso em: 28 set. 2025.

APÊNDICE 1 – INTRODUÇÃO À INTELIGÊNCIA ARTIFICIAL

A – ENUNCIADO

1 ChatGPT

a) **(6,25 pontos)** Pergunte ao ChatGPT o que é Inteligência Artificial e cole aqui o resultado.
b) **(6,25 pontos)** Dada essa resposta do ChatGPT, classifique usando as 4 abordagens vistas em sala. Explique o porquê.
c) **(6,25 pontos)** Pesquise sobre o funcionamento do ChatGPT (sem perguntar ao próprio ChatGPT) e escreva um texto contendo no máximo 5 parágrafos. Cite as referências.
d) **(6,25 pontos)** Entendendo o que é o ChatGPT, classifique o próprio ChatGPT usando as 4 abordagens vistas em sala. Explique o porquê.

2 Busca Heurística

Realize uma busca utilizando o algoritmo A* para encontrar o melhor caminho para chegar a **Bucharest** partindo de **Lugoj**. Construa a árvore de busca criada pela execução do algoritmo apresentando os valores de *f(n)*, *g(n)* e *h(n)* para cada nó. Utilize a heurística de distância em linha reta, que pode ser observada na tabela abaixo.

Essa tarefa pode ser feita em uma **ferramenta de desenho**, ou até mesmo no **papel**, desde que seja digitalizada (foto) e convertida para PDF.

a) **(25 pontos)** Apresente a árvore final, contendo os valores, da mesma forma que foi apresentado na disciplina e nas práticas. Use o formato de árvore, não será permitido um formato em blocos, planilha, ou qualquer outra representação.

NÃO É NECESSÁRIO IMPLEMENTAR O ALGORITMO.

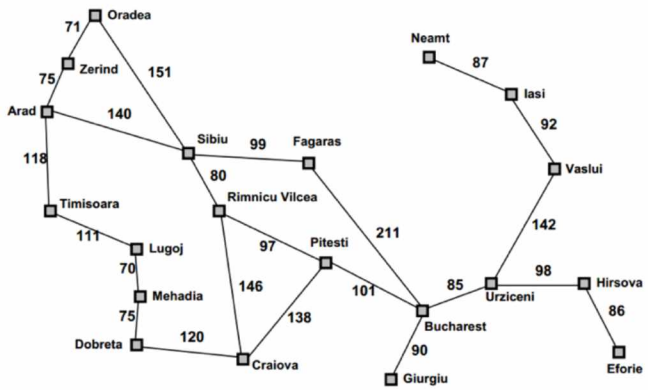

Arad	366	**Mehadia**	241
Bucareste	0	**Neamt**	234
Craiova	160	**Oradea**	380
Drobeta	242	**Pitesti**	100
Eforie	161	**Rimnicu Vilcea**	193
Fagaras	176	**Sibiu**	253
Giurgiu	77	**Timisoara**	329
Hirsova	151	**Urziceni**	80
Iasi	226	**Vaslui**	199
Lugoj	244	**Zerind**	374

Figura 3.22 Valores de *hDLR* — distâncias em linha reta para Bucareste.

3 Lógica

Verificar se o argumento lógico é válido.

Se as uvas caem, então a raposa as come
Se a raposa as come, então estão maduras
As uvas estão verdes ou caem

Logo

A raposa come as uvas se e somente se as uvas caem

Deve ser apresentada uma prova, no mesmo formato mostrado nos conteúdos de aula e nas práticas.

Dicas:

1. Transformar as afirmações para lógica:

p: as uvas caem
q: a raposa come as uvas
r: as uvas estão maduras

2. Transformar as três primeiras sentenças para formar a base de conhecimento

R1: $p \rightarrow q$
R2: $q \rightarrow r$
R3: $\neg r \vee p$

3. Aplicar equivalências e regras de inferência para se obter o resultado esperado. Isto é, com essas três primeiras sentenças devemos derivar $q \leftrightarrow p$. Cuidado com a ordem em que as fórmulas são geradas.

Equivalência Implicação: $(\alpha \rightarrow \beta)$ equivale a $(\neg\alpha \vee \beta)$

Silogismo Hipotético: $\alpha \rightarrow \beta, \beta \rightarrow \gamma \vdash \alpha \rightarrow \gamma$

Conjunção: $\alpha, \beta \vdash \alpha \wedge \beta$

Equivalência Bicondicional: $(\alpha \leftrightarrow \beta)$ equivale a $(\alpha \rightarrow \beta) \wedge (\beta \rightarrow \alpha)$

a) **(25 pontos)** Deve-se mostrar todos os passos e regras aplicadas, **no mesmo formato apresentado nas aulas e nas práticas**. As equivalências e regras necessárias estão descritas acima e no material.

4 Redes Neurais Artificiais

Seja a RNA da figura abaixo.

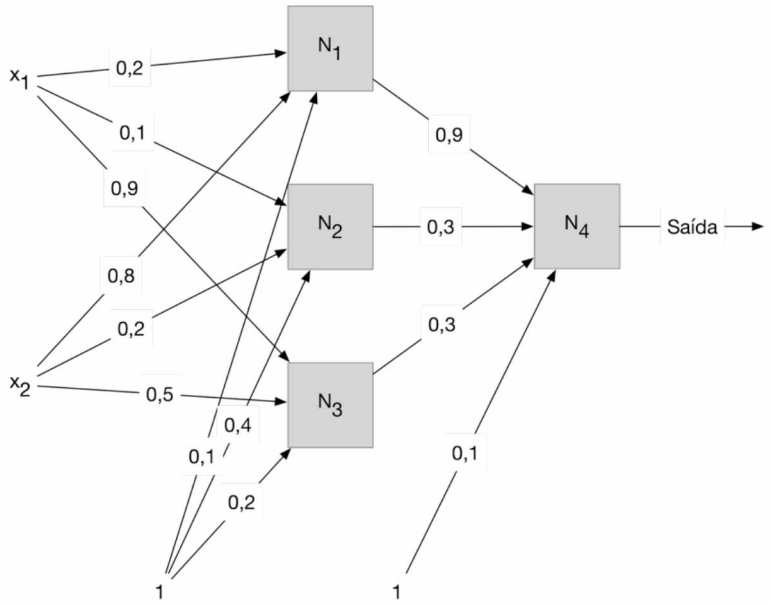

Os neurônios N_1, N_2 e N_3 possuem função de ativação linear. Já N_4 possui função de ativação tangente hiperbólica (pesquise a fórmula e aplique).

Dada a entrada x_1=-3, x_2=1, dê:

a) **(6,25 pontos)** Valor de saída do neurônio N1
b) **(6,25 pontos)** Valor de saída do neurônio N2
c) **(6,25 pontos)** Valor de saída do neurônio N3
d) **(6,25 pontos)** Valor de saída da rede como um todo

B – RESOLUÇÃO

1 ChatGPT

a) Pergunte ao ChatGPT o que é Inteligência Artificial e cole aqui o resultado.

Inteligência Artificial (IA) é um campo da ciência da computação que se concentra no desenvolvimento de sistemas e máquinas capazes de realizar tarefas que normalmente requerem inteligência humana. Essas tarefas podem incluir raciocínio, aprendizado, reconhecimento de padrões, resolução de problemas, compreensão de linguagem natural, entre outras.

Os sistemas de IA são projetados para simular certos aspectos do comportamento humano, como a capacidade de aprender com experiências passadas, tomar decisões baseadas em dados e adaptar-se a novas situações. Eles podem ser aplicados em uma ampla variedade de áreas, incluindo medicina, finanças, transporte, manufatura, entretenimento, entre outros.

Existem diferentes abordagens e técnicas dentro do campo da IA, incluindo o aprendizado de máquina, redes neurais artificiais, lógica simbólica, algoritmos evolutivos, entre outras. O objetivo final da IA é criar sistemas capazes de realizar tarefas de forma autônoma, eficiente e com desempenho comparável ou superior ao humano em determinadas áreas.

b) Dada essa resposta do ChatGPT, classifique usando as 4 abordagens vistas em sala. Explique o porquê.

A resposta, acima, dada pelo ChatGPT, pode ser enquadrada nas quatro abordagens, conforme análise a seguir:

Agir como Humano: a resposta descreve a capacidade de sistemas de IA em realizar tarefas que requerem inteligência humana, como raciocínio, reconhecimento de padrões, interpretação de informações e compreensão da linguagem natural. Isso se assemelha com a abordagem de agir como humano, pois imita o comportamento de humanos diante de certas atividades como, por exemplo, ser capaz de interpretar e engajar-se em uma conversa. A representação do conhecimento se dá por meio de processamento de linguagem natural.

Pensar como Humano: essa abordagem busca a implementação do processo de pensamento, ou seja, codificar para o computador a forma de funcionamento do cérebro humano. Esse aspecto pode ser identificado na resposta do ChatGPT quando mencionada a simulação de aspectos do comportamento humano, como a capacidade de aprender com experiências passadas, adaptar-se a novas situações e interpretar informações.

Agir Racionalmente: a resposta destaca a capacidade de sistemas de IA em realizar tarefas que requerem inteligência humana, de tomar decisões e de realizar tarefas de forma eficaz, incluindo adaptação a novas situações. Desta forma, a resposta associa-se ao Agir Racionalmente, visto que esta abordagem é a mais ampla das quatro abordagens. Envolve a implementação de sistemas/agentes capazes de responder a situações e buscar tomar as melhores ações possíveis para atingir objetivo definido.

Pensar Racionalmente: essa abordagem busca modelar o processo de raciocínio para que os sistemas de IA possam operar de acordo com princípios de raciocínio lógico e dedutivo. Na resposta fornecida pelo ChatGPT podemos associar o trecho "sistemas capazes de realizar tarefas" com o Pensar Racionalmente, visto que para realizar uma tarefa é necessário algum uso de raciocínio lógico e dedutivo.

c) Pesquise sobre o funcionamento do ChatGPT (sem perguntar ao próprio ChatGPT) e escreva um texto contendo no máximo 5 parágrafos. Cite as referências.

O ChatGPT pode ser definido como um Modelo de Linguagem de Grande Porte (LLM), projetado para processamento de linguagem natural. Esse tipo de modelo é exposto a quantidade massivas de dados para, assim, aprender os padrões estatísticos da linguagem.

Os LLM são construídos com base na arquitetura de Transformer, uma estrutura de rede neural proposta por Vaswani et al. no trabalho "Attention is All You Need" em 2017. Essa arquitetura se constitui de vários neurônios interconectados (unidades de atenção), o que permite que este modelo processe informações em paralelo, capturando relacionamentos de longo alcance entre palavras em uma sentença. Isso permite que o ChatGPT gere respostas coerentes e contextuais.

Além disso, o ChatGPT é refinado por meio do processo de fine-tuning, onde é ajustado para tarefas específicas e também recebe feedback humano para melhorar seu desempenho. O processo de Aprendizado por Reforço com Feedback Humano (RLHF), onde as interações humanas são usadas para orientar o comportamento do modelo em direção aos resultados desejados, ajuda a garantir que o ChatGPT possa fornecer respostas úteis e evitar a geração de conteúdo problemático. Portanto, tal processo pode ser entendido como uma salvaguarda aplicada ao modelo.

Em resumo, o ChatGPT é uma combinação de técnicas de aprendizado de máquina e processamento de linguagem natural, projetado para entender e responder a perguntas de maneira semelhante a um ser humano.

Referências:

https://help.openai.com/en/articles/6783457-what-is-chatgpt
https://platform.openai.com/docs/introduction
https://www.consultingclub.com.br/post/intelig%C3%AAncias-artificiais-e-o-chat-gpt-o-futuro-j%C3%A1-come%C3%A7ou
https://towardsdatascience.com/how-chatgpt-works-the-models-behind-the-bot-1ce5fca96286
https://www.datacamp.com/blog/a-chat-with-chatgpt-on-the-method-behind-the-bot
https://www.engenhariahibrida.com.br/post/a-tecnologia-por-tras-do-chat-gpt#:~:text=O%20Chat%20GPT%2C%20alimentado%20por,artificial%20por%20meio%20de%20texto.
https://www.dio.me/articles/conheca-a-tecnologia-por-tras-do-chatgpt-o-que-e-e-como-usar-a-ferramenta-na-programacao
https://www.youtube.com/watch?v=VcAAXzCKX_g
https://www.youtube.com/watch?v=bSvTVREwSNw
Lee, Peter, et al. A Revolução da Inteligência Artificial na Medicina: GPT-4 e Além. Disponível em: Minha Biblioteca, Grupo A, 2024.

d) Entendendo o que é o ChatGPT, classifique o próprio ChatGPT usando as 4 abordagens vistas em sala. Explique o porquê.

O modo de funcionamento do ChatGPT enquadra-se na abordagem “Agir como humanos”, devido a compreensão da linguagem natural e a capacidade de responder perguntas, conversar e até mesmo gerar novos conteúdos textuais, utilizando-se da linguagem natural para apresentar seus resultados imitando o comportamento humano. O ChatGPT não pensa como um humano, suas respostas são baseadas em conhecimento obtido através de seus métodos de aprendizagem.

2 Busca Heurística

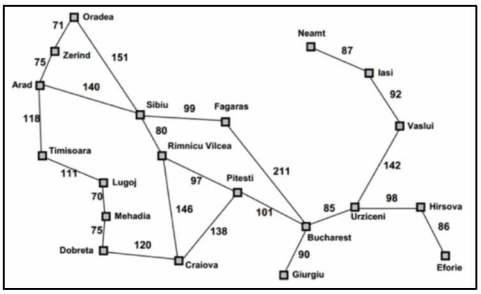

Arad	366	Mehadia	241
Bucareste	0	Neamt	234
Craiova	160	Oradea	380
Drobeta	242	Pitesti	100
Eforie	161	Rimnicu Vilcea	193
Fagaras	176	Sibiu	253
Giurgiu	77	Timisoara	329
Hirsova	151	Urziceni	80
Iasi	226	Vaslui	199
Lugoj	244	Zerind	374

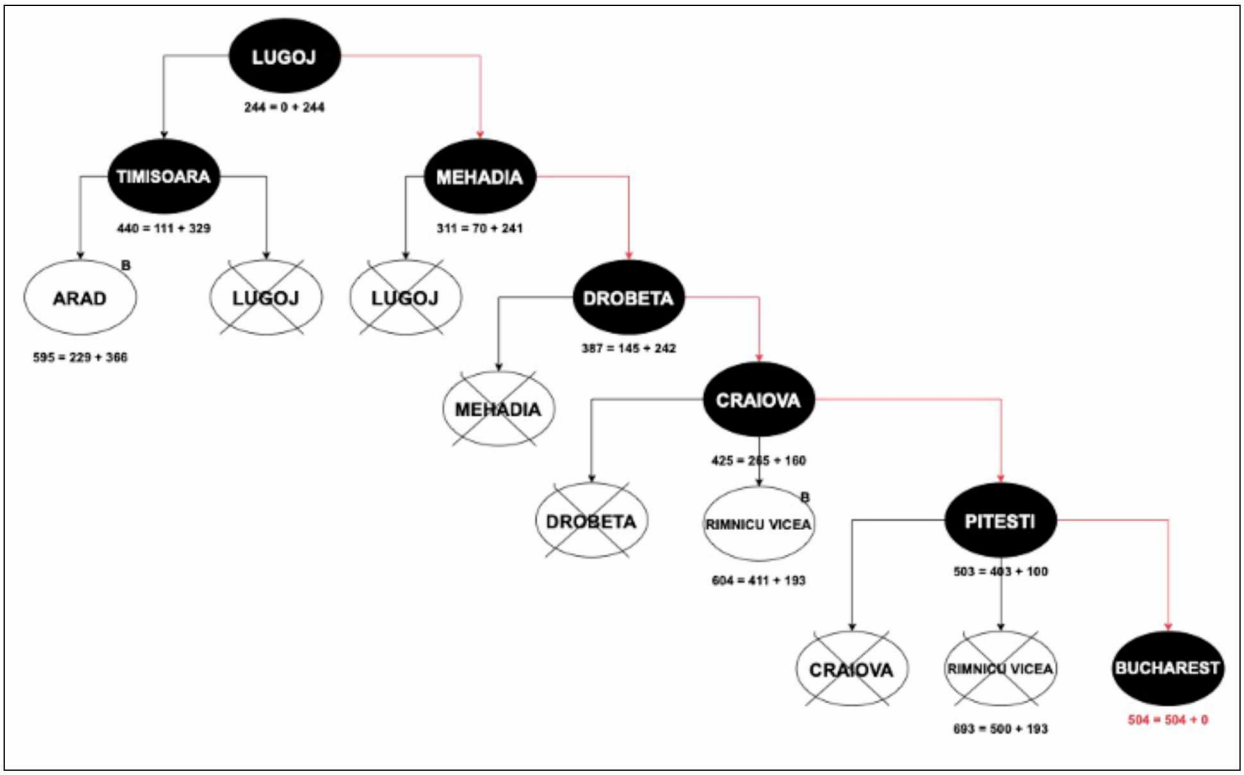

3 Lógica

R1: p → q

R2: q → r

R3: ¬r ∨ p

R4: r → p (Equivalência Implicação em R3)

R5: q → p (Silogismo Hipotético em R2 e R4)

R6: (q → p) ∧ (p → q) (Conjunção entre R5 e R1)

R7: q ↔ p (Equivalência Bi condicional em R6)

4 Redes Neurais Artificiais

a) Valor de saída do neurônio N1

u(N1) = (0,2 * -3) + (0,8 * 1) + (0,1 * 1)

u(N1) = -0,6 + 0,8 + 0,1

u(N1) = 0,3

f(u) = 0,3

b) Valor de saída do neurônio N2
u(N2) = (0,1 * -3) + (0,2 * 1) + (0,4 * 1)
u(N2) = -0,3 + 0,2 + 0,4
u(N2) = 0,3
f(u) = 0,3

c) Valor de saída do neurônio N3
u(N3) = (0,9 * -3) + (0,5 * 1) + (0,2 * 1)
u(N3) = -2,7 + 0,5 + 0,2
u(N3) = -2
f(u) = -2

d) Valor de saída da rede como um todo
u(N4) = (0,9 * 0,3) + (0,3 * 0,3) + (0,3 * -2) + (0,1 * 1)
u(N4) = 0,27 + 0,09 - 0,6 + 0,1
u(N4) = -0,14
f(u) = tanh(u) = -0,139092448

APÊNDICE 2 – LINGUAGEM DE PROGRAMAÇÃO APLICADA

A – ENUNCIADO

Nome da base de dados do exercício: *precos_carros_brasil.csv*

Informações sobre a base de dados:

Dados dos preços médios dos carros brasileiros, das mais diversas marcas, no ano de 2021, de acordo com dados extraídos da tabela FIPE (Fundação Instituto de Pesquisas Econômicas). A base original foi extraída do site Kaggle (Acesse aqui a base original). A mesma foi adaptada para ser utilizada no presente exercício.

Observação: As variáveis *fuel*, *gear* e *engine_size* foram extraídas dos valores da coluna *model*, pois na base de dados original não há coluna dedicada a esses valores. Como alguns valores do modelo não contêm as informações do tamanho do motor, este conjunto de dados não contém todos os dados originais da tabela FIPE.

Metadados:

Nome do campo	Descrição
year_of_reference	O preço médio corresponde a um mês de ano de referência
month_of_reference	O preço médio corresponde a um mês de referência, ou seja, a FIPE atualiza sua tabela mensalmente
fipe_code	Código único da FIPE
authentication	Código de autenticação único para consulta no site da FIPE
brand	Marca do carro
model	Modelo do carro
fuel	Tipo de combustível do carro
gear	Tipo de engrenagem do carro
engine_size	Tamanho do motor em centímetros cúbicos

year_model	Ano do modelo do carro. Pode não corresponder ao ano de fabricação
avg_price	Preço médio do carro, em reais

Atenção: ao fazer o download da base de dados, selecione o formato .csv. É o formato que será considerado correto na resolução do exercício.

1 Análise Exploratória dos dados

A partir da base de dados **precos_carros_brasil.csv**, execute as seguintes tarefas:

a. Carregue a base de dados media_precos_carros_brasil.csv
b. Verifique se há valores faltantes nos dados. Caso haja, escolha uma tratativa para resolver o problema de valores faltantes
c. Verifique se há dados duplicados nos dados
d. Crie duas categorias, para separar colunas numéricas e categóricas. Imprima o resumo de informações das variáveis numéricas e categóricas (estatística descritiva dos dados)
e. Imprima a contagem de valores por modelo (model) e marca do carro (brand)
f. Dê um breve explicação (máximo de quatro linhas) sobre os principais resultados encontrados na Análise Exploratória dos dados

2 Visualização dos dados

A partir da base de dados **precos_carros_brasil.csv,** execute as seguintes tarefas:

a. Gere um gráfico da distribuição da quantidade de carros por marca
b. Gere um gráfico da distribuição da quantidade de carros por tipo de engrenagem do carro
c. Gere um gráfico da evolução da média de preço dos carros ao longo dos meses de 2022 (variável de tempo no eixo X)
d. Gere um gráfico da distribuição da média de preço dos carros por marca e tipo de engrenagem
e. Dê uma breve explicação (máximo de quatro linhas) sobre os resultados gerados no item d
f. Gere um gráfico da distribuição da média de preço dos carros por marca e tipo de combustível
g. Dê uma breve explicação (máximo de quatro linhas) sobre os resultados gerados no item f

3 Aplicação de modelos de machine learning para prever o preço médio dos carros

A partir da base de dados **precos_carros_brasil.csv**, execute as seguintes tarefas:

a. Escolha as variáveis **numéricas** (modelos de Regressão) para serem as variáveis independentes do modelo.A variável target é **avg_price. Observação:** caso julgue necessário, faça a transformação de variáveis categóricas em variáveis numéricas para inputar no modelo. Indique **quais variáveis** foram transformadas e **como** foram transformadas
b. Crie partições contendo 75% dos dados para treino e 25% para teste
c. Treine modelos RandomForest (biblioteca RandomForestRegressor) e XGBoost (biblioteca XGBRegressor) para predição dos preços dos carros. **Observação**: caso julgue necessário, mude os parâmetros dos modelos e rode novos modelos. Indique quais parâmetros foram inputados e indique o treinamento de cada modelo
d. Grave os valores preditos em variáveis criadas
e. Realize a análise de importância das variáveis para estimar a variável target, **para cada modelo treinado**

f. Dê uma breve explicação (máximo de quatro linhas) sobre os resultados encontrados na análise de importância de variáveis
g. Escolha o melhor modelo com base nas métricas de avaliação MSE, MAE e R^2
h. Dê uma breve explicação (máximo de quatro linhas) sobre qual modelo gerou o melhor resultado e a métrica de avaliação utilizada

B - RESOLUÇÃO

```
## 1 Análise Exploratória dos Dados
# Importar bibliotecas analise dados e gráficos
import pandas as pd
import seaborn as sns
import matplotlib.pyplot as plt
from datetime import datetime
from time import strptime
import warnings
warnings.filterwarnings('ignore')
```

Questão 1.a)

```
# Importar a base de dados CSV - precos_carros_brasil.csv
tbDados = pd.read_csv("precos_carros_brasil.csv")

# Mostra o cabeçalho e pequena sequencia de dados
tbDados
```

	year_of_reference	month_of_reference	fipe_code	authentication	brand	model	fuel	gear	engine_size	year_model	avg_price_brl
0	2021.0	January	004001-0	cfzlctzfwrcp	GM - Chevrolet	Corsa Wind 1.0 MPFI / EFI 2p	Gasoline	manual	1	2002.0	9162.0
1	2021.0	January	004001-0	cdqwxwpw3y2p	GM - Chevrolet	Corsa Wind 1.0 MPFI / EFI 2p	Gasoline	manual	1	2001.0	8832.0
2	2021.0	January	004001-0	cb1t3xwwj1xp	GM - Chevrolet	Corsa Wind 1.0 MPFI / EFI 2p	Gasoline	manual	1	2000.0	8388.0
3	2021.0	January	004001-0	cb9gct6j65r0	GM - Chevrolet	Corsa Wind 1.0 MPFI / EFI 2p	Alcohol	manual	1	2000.0	8453.0
4	2021.0	January	004003-7	g15wg0gbz1fx	GM - Chevrolet	Corsa Pick-Up GL/ Champ 1.6 MPFI / EFI	Gasoline	manual	1,6	2001.0	12525.0
...	...	...	...	...	...	...	...	...	...	...	...
267537	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN
267538	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN
267539	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN
267540	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN
267541	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN

267542 rows × 11 columns

Questão 1.b)

```
# Verificar se faltam valores e tratativa para resolução do problema
# *** HÁ ITENS FALTANTES EM TODAS AS 11 COLUNAS ***
tbDados.isna().any()
year_of_reference     True
month_of_reference    True
fipe_code             True
authentication        True
brand                 True
model                 True
fuel                  True
```

```
gear                  True
engine_size           True
year_model            True
avg_price_brl         True
dtype: bool

# Contagem de itens faltantes
tbDados.isna().sum()
year_of_reference     65245
month_of_reference    65245
fipe_code             65245
authentication        65245
brand                 65245
model                 65245
fuel                  65245
gear                  65245
engine_size           65245
year_model            65245
avg_price_brl         65245
dtype: int64

# EXISTEM ITENS FALTANTES - Opção por apagar itens faltantes
tbDados.dropna(inplace=True)

# Verifica novamente se existem itens faltantes
# *** NÃO HÁ MAIS ITENS FALTANTES ***
tbDados.isna().any()
year_of_reference     False
month_of_reference    False
fipe_code             False
authentication        False
brand                 False
model                 False
fuel                  False
gear                  False
engine_size           False
year_model            False
avg_price_brl         False
dtype: bool

# Realiza nova contagem dos itens faltantes
```

```
tbDados.isna().sum()
year_of_reference      0
month_of_reference     0
fipe_code              0
authentication         0
brand                  0
model                  0
fuel                   0
gear                   0
engine_size            0
year_model             0
avg_price_brl          0
dtype: int64
```

Questão 1.c)

```
# Verificar se há itens duplicados
tbDados.duplicated().sum()
2

# Exclui itens duplicados
tbDados.drop_duplicates(inplace=True)

# Verifica novamente se há itens duplicados
tbDados.duplicated().sum()
0
```

Questão 1.d)

```
# Dividir a categoria dos dados e impressão do resumo de informações das
    variáveis numéricas e categóricas
num_colms = [col for col in tbDados.columns if tbDados[col].dtype != 'object']
cat_colms = [col for col in tbDados.columns if tbDados[col].dtype == 'object']

# Impressão das infomações das variáveis numéricas
tbDados[num_colms].describe()
```

	year_of_reference	year_model	avg_price_brl
count	202295.000000	202295.000000	202295.000000
mean	2021.564695	2011.271514	52756.765713
std	0.571904	6.376241	51628.912116
min	2021.000000	2000.000000	6647.000000
25%	2021.000000	2006.000000	22855.000000
50%	2022.000000	2012.000000	38027.000000
75%	2022.000000	2016.000000	64064.000000
max	2023.000000	2023.000000	979358.000000

```
# Impressão das infomações das variáveis categóricas
tbDados[cat_colms].describe()
```

	month_of_reference	fipe_code	authentication	brand	model	fuel	gear	engine_size
count	202295	202295	202295	202295	202295	202295	202295	202295
unique	12	2091	202295	6	2112	3	2	29
top	January	003281-6	cfzlctzfwrcp	Fiat	Palio Week. Adv/Adv TRYON 1.8 mpi Flex	Gasoline	manual	1,6
freq	24260	425	1	44962	425	168684	161883	47420

Questão 1.e)

```
# Impressão de valores por contagem de modelo (model) e marca do carro (brand)

#Impressão por modelo
tbDados["model"].value_counts()
```

```
model
Palio Week. Adv/Adv TRYON 1.8 mpi Flex    425
Focus 1.6 S/SE/SE Plus Flex 8V/16V 5p     425
Focus 2.0 16V/SE/SE Plus Flex 5p Aut.     400
Saveiro 1.6 Mi/ 1.6 Mi Total Flex 8V      400
Corvette 5.7/ 6.0, 6.2 Targa/Stingray     375
                                         ...
STEPWAY Zen Flex 1.0 12V Mec.               2
Saveiro Robust 1.6 Total Flex 16V CD        2
Saveiro Robust 1.6 Total Flex 16V           2
Gol Last Edition 1.0 Flex 12V 5p            2
Polo Track 1.0 Flex 12V 5p                  2
Name: count, Length: 2112, dtype: int64
```

```
# Impressão por marca
tbDados["brand"].value_counts()
```

```
brand
Fiat                44962
VW - VolksWagen     44312
GM - Chevrolet      38590
Ford                33150
Renault             29191
Nissan              12090
Name: count, dtype: int64
```

Questão 1.f)

Dê uma breve explicação (máximo de quatro linhas) sobre os principais resultados encontrados na Análise Exploratória dos dados.

Durante a importação e tratamento dos dados observou-se a existência de 65.245 dados faltantes e dois duplicados sendo necessária a aplicação de correções para eliminar estes problemas. Em relação aos dados, observou-se que as marcas Fiat, Volkswagen e Chevrolet são predominantes no conjunto de dados. Foi possível constatar que a maioria dos veículos tem um preço médio superior a 60 mil, são movidos a gasolina, e possuem câmbio manual.

Questão 2.a)

```
# Gerar gráfico da distribuição da quantidade de carros por marca
```

```
# Contagem dos valores por marca
valBrand = tbDados["brand"].value_counts()
print(valBrand
```

```
brand
Fiat                44962
VW - VolksWagen     44312
GM - Chevrolet      38590
Ford                33150
Renault             29191
Nissan              12090
Name: count, dtype: int64
```

```
# Gráfico comparativo
plt.figure(figsize=(10,5))
grfBrand = plt.bar(valBrand.index, valBrand.values)
plt.title('Quantidade de Carros por Marca')
plt.xlabel('Marcas Veículos')
plt.ylabel('Total de Carros')
plt.bar_label(grfBrand, size=10);
```

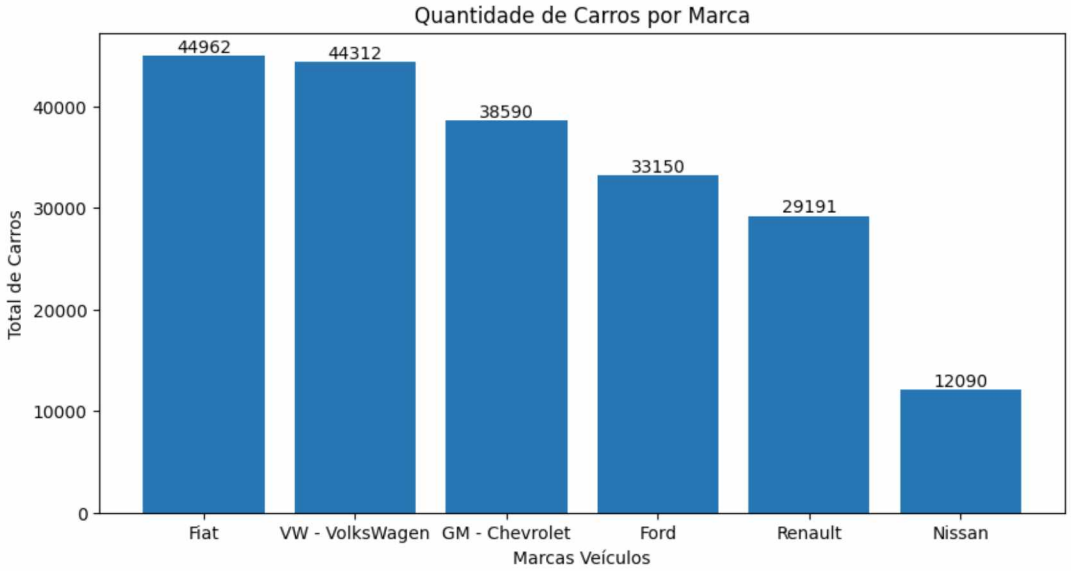

Questão 2.b)

```
# Gerar gráfico da quantidade de carros por tipo de engrenagem
# Contagem dos valores por engrenagem
tpEngr = tbDados["gear"].value_counts()
print(tpEngr)
gear
manual       161883
automatic     40412
Name: count, dtype: int64
```

```
# Gráfico comparativo
plt.figure(figsize=(10,5
grfEngr = plt.bar(tpEngr.index, tpEngr.values)
plt.title('Quantidade por Tipo de Engrenagens')
plt.ylabel('Total de Engrenagem')
plt.bar_label(grfEngr, size=10);
```

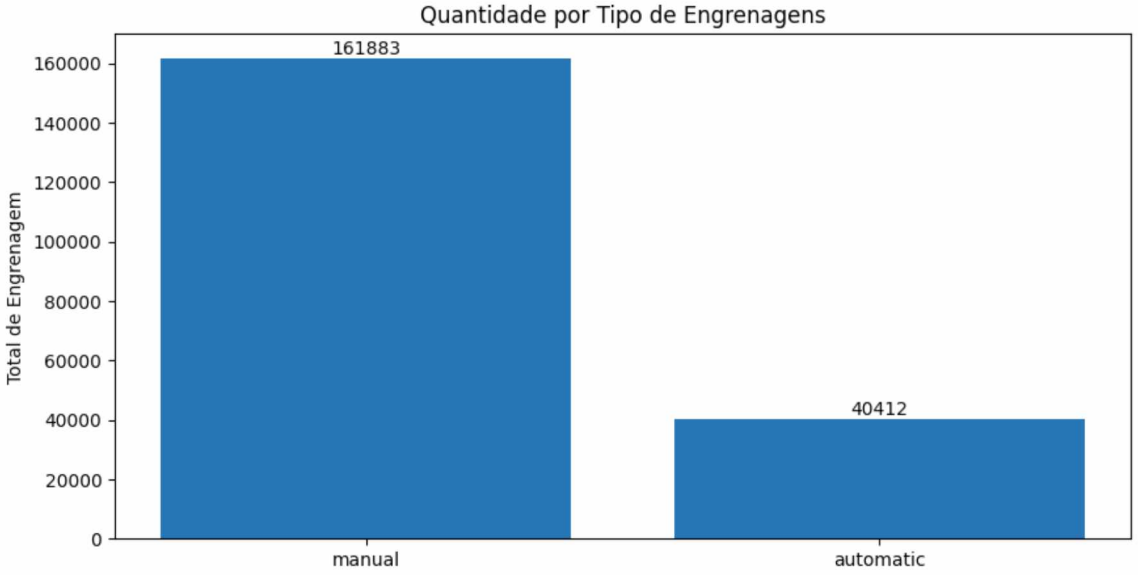

Questão 2.c)

```
# Gerar gráfico da evolução da média de preços dos carros ao longo do ano de
2022 - Representar os meses no eixo X
# Separando apenas dados de 2022
yearRef = tbDados[tbDados['year_of_reference'] == 2022]

# Criando coluna para representar os valorese numericos dos meses
yearRef['month_of_reference_numeric'] = [strptime(mes, '%B').tm_mon for mes
in yearRef['month_of_reference']]
mdMes                                                                    =
yearRef.groupby(['month_of_reference_numeric','month_of_reference'])['avg_p
rice_brl'].mean()
```

```
# Gerando gráfico de linha
plt.plot(mdMes.index.get_level_values('month_of_reference'), mdMes, "b-")
plt.xlabel("Mês")
plt.ylabel("Preço Médio (BRL)")
plt.title("Preço Médio por Mês em 2022")
plt.xticks(rotation=30)
plt.grid(True)
```

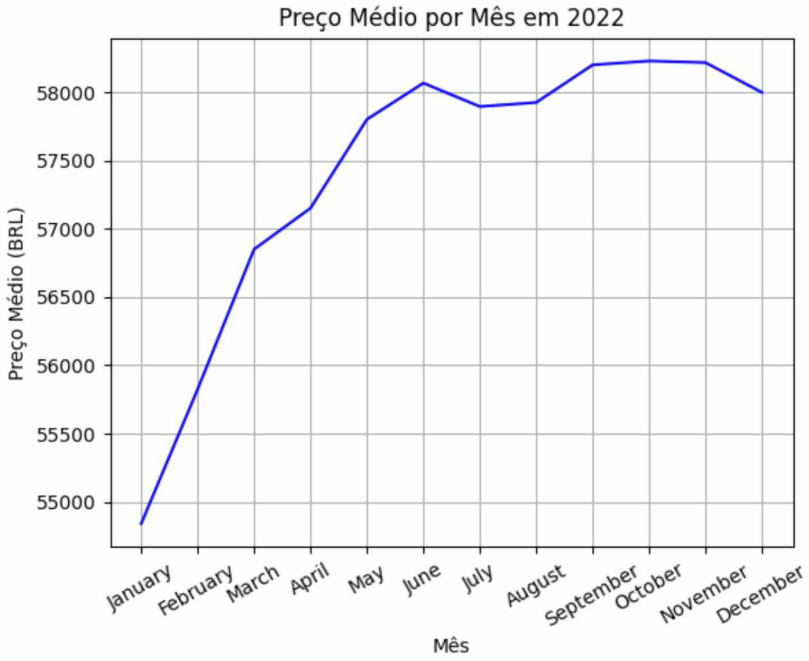

Questão 2.d)

```
# Gerar um gráfico da distribuição da média de preços dos carros por marca e tipo de engrenagem
# Separando apenas dados por preços
refPrice = tbDados.groupby(['brand', 'gear']).avg_price_brl.mean().reset_index()

# Gerando o gráfico
plt.figure(figsize=(20, 10))
Cores = dict(zip(refPrice['brand'].unique(), sns.color_palette("husl", len(refPrice['brand'].unique()))))

for marca in refPrice['brand'].unique():
    for engrenagem in refPrice['gear'].unique():
        dados = refPrice[(refPrice['brand'] == marca) & (refPrice['gear'] == engrenagem)]
        plt.bar(f'{marca} - {engrenagem}', dados['avg_price_brl'], label=f'{marca} - {engrenagem}')
```

```
        if not dados.empty:
            plt.bar(f'{marca} - {engrenagem}', dados['avg_price_brl'],
color=Cores[marca], label=f'{marca} - {engrenagem}')

plt.xticks(rotation=75)
plt.title('Distribuição da Média de Preço dos Carros por Marca e Tipo de
Engrenagem')
plt.xlabel('Veículos | Tipo de Engrenagem')
plt.ylabel('Média de Preço')
```

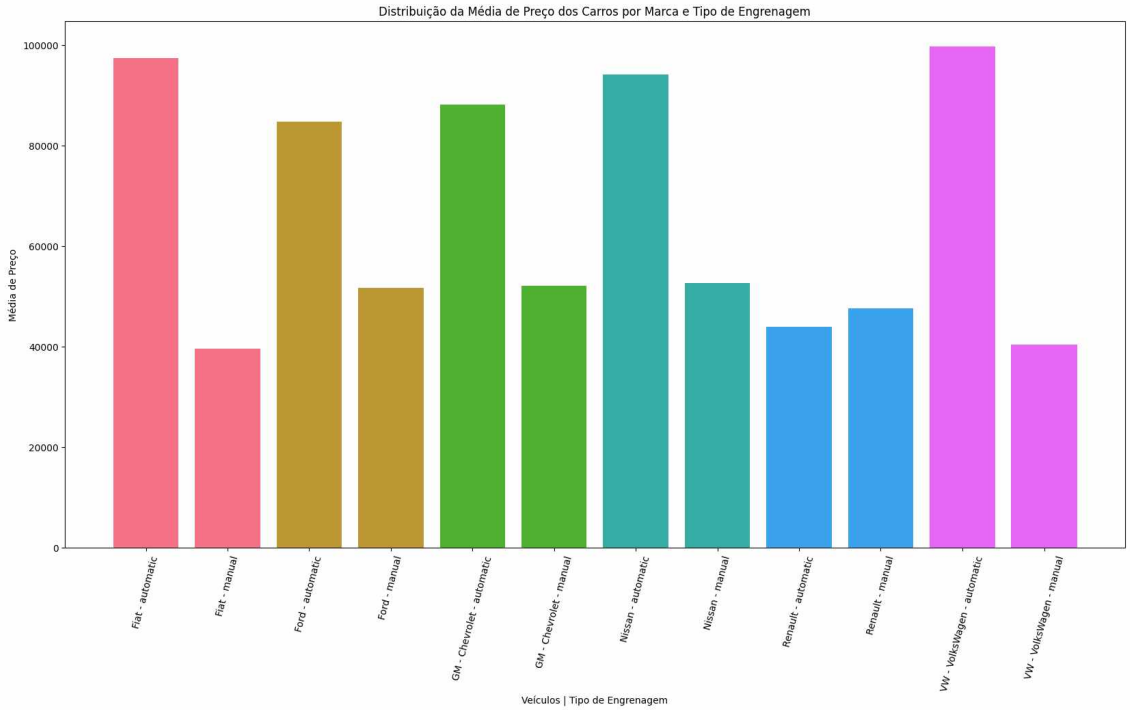

Questão 2.e)

O gráfico demonstra que as marcas Volkswagem, Fiat, e Nissan, possuem, respectivamente, as médias mais altas de preços para cambio automático. Já o modelo automático da marca Renault possui média de preço um pouco superior quando comparado aos carros das marcas Volkswagem e Fiat com câmbio manual. Pode-se concluir que os carros automáticos têm preço superior quando comparados a carros manuais.

Questão 2.f)

```
# Gerar um gráfico da distribuição da média de preços dos carros por marca e
tipo de combustível
# Separando apenas dados por preços
refPrice = tbDados.groupby(['brand',
'fuel']).avg_price_brl.mean().reset_index()
```

```
# Gerando o gráfico
plt.figure(figsize=(20, 10))
Cores = dict(zip(refPrice['brand'].unique(), sns.color_palette("husl",
len(refPrice['brand'].unique()))))

for marca in refPrice['brand'].unique():
    for combustivel in refPrice['fuel'].unique():
        dados = refPrice[(refPrice['brand'] == marca) & (refPrice['fuel'] ==
combustivel)]
        for i, row in refPrice.iterrows():
            plt.bar(f'{row["brand"]} - {row["fuel"]}', row['avg_price_brl'],
color=Cores[row['brand']], label=f'{row["brand"]} - {row["fuel"]}')

plt.xticks(rotation=75)
plt.title('Distribuição da Média de Preço dos Carros por Marca e Tipo de
Combustível')
plt.xlabel('Veículos | Tipo de Combustível')
plt.ylabel('Média de Preço');
```

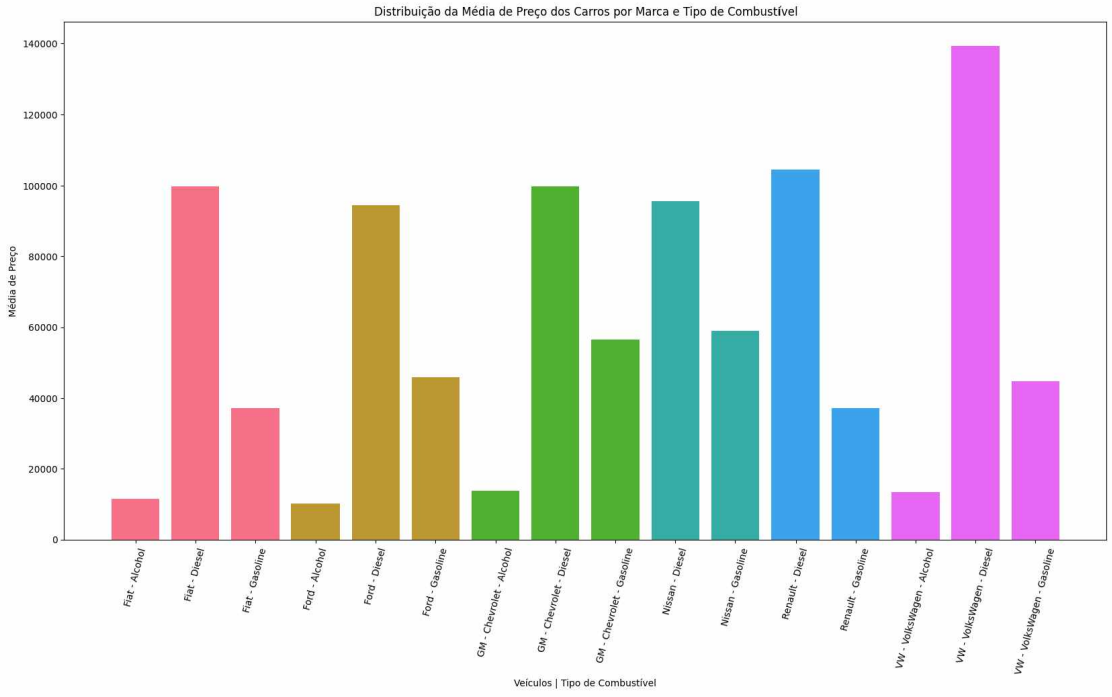

Questão 2.g)

Veículos movidos a diesel possuem maior média de preço, seguidos pelos movidos a gasolina e, por fim, pelos movidos a álcool. Adicionalmente, observa-se que as marcas Renault e Nissan não possuem modelos movidos a álcool.

Questão 3.a)

```
# Importação bibliotecas de Machine Learning
from sklearn.model_selection import train_test_split
from sklearn.ensemble import RandomForestRegressor
from xgboost import XGBRegressor
from sklearn.preprocessing import LabelEncoder

# Métricas de avaliação dos modelos
from sklearn.metrics import mean_squared_error, mean_absolute_error, r2_score

# Mostrando tabela de dados original "limpa"
tbDados
```

	year_of_reference	month_of_reference	fipe_code	authentication	brand	model	fuel	gear	engine_size	year_model	avg_price_brl
0	2021.0	January	004001-0	cfzlctzfwrcp	GM - Chevrolet	Corsa Wind 1.0 MPFI / EFI 2p	Gasoline	manual	1	2002.0	9162.0
1	2021.0	January	004001-0	cdqwxwpw3y2p	GM - Chevrolet	Corsa Wind 1.0 MPFI / EFI 2p	Gasoline	manual	1	2001.0	8832.0
2	2021.0	January	004001-0	cb1t3xwwj1xp	GM - Chevrolet	Corsa Wind 1.0 MPFI / EFI 2p	Gasoline	manual	1	2000.0	8388.0
3	2021.0	January	004001-0	cb9gct6j65r0	GM - Chevrolet	Corsa Wind 1.0 MPFI / EFI 2p	Alcohol	manual	1	2000.0	8453.0
4	2021.0	January	004003-7	g15wg0gbz1fx	GM - Chevrolet	Corsa Pick-Up GL/ Champ 1.6 MPFI / EFI	Gasoline	manual	1,6	2001.0	12525.0
...	...	...	...	...	...	...	...	...	...	...	...
202292	2023.0	January	005538-7	ccv3mvxnsz0dqw	VW - VolksWagen	Saveiro Robust 1.6 Total Flex 16V	Gasoline	manual	1,6	2023.0	86038.0
202293	2023.0	January	005539-5	chmwfg3l5hbp	VW - VolksWagen	Gol Last Edition 1.0 Flex 12V 5p	Gasoline	manual	1	2023.0	95997.0
202294	2023.0	January	005539-5	cdj27srtcvcdqw	VW - VolksWagen	Gol Last Edition 1.0 Flex 12V 5p	Gasoline	manual	1	2023.0	87828.0
202295	2023.0	January	005540-9	9w64fg6dhqp	VW - VolksWagen	Polo Track 1.0 Flex 12V 5p	Gasoline	manual	1	2023.0	80845.0
202296	2023.0	January	005540-9	7hbnjmj9z5dqw	VW - VolksWagen	Polo Track 1.0 Flex 12V 5p	Gasoline	manual	1	2023.0	74458.0

202295 rows × 11 columns

```
# Elegidas as seguintes variáveis: year_of_reference, brand, fuel, gear, engine_size, year_model

tbDados_Regr = tbDados[['year_of_reference','brand','fuel','gear','engine_size','year_model','avg_price_brl']]
tbDados_Regr
```

	year_of_reference	brand	fuel	gear	engine_size	year_model	avg_price_brl
0	2021.0	GM - Chevrolet	Gasoline	manual	1	2002.0	9162.0
1	2021.0	GM - Chevrolet	Gasoline	manual	1	2001.0	8832.0
2	2021.0	GM - Chevrolet	Gasoline	manual	1	2000.0	8388.0
3	2021.0	GM - Chevrolet	Alcohol	manual	1	2000.0	8453.0
4	2021.0	GM - Chevrolet	Gasoline	manual	1,6	2001.0	12525.0
...	...	...	...	...	...	...	...
202292	2023.0	VW - VolksWagen	Gasoline	manual	1,6	2023.0	86038.0
202293	2023.0	VW - VolksWagen	Gasoline	manual	1	2023.0	95997.0
202294	2023.0	VW - VolksWagen	Gasoline	manual	1	2023.0	87828.0
202295	2023.0	VW - VolksWagen	Gasoline	manual	1	2023.0	80845.0
202296	2023.0	VW - VolksWagen	Gasoline	manual	1	2023.0	74458.0

202295 rows × 7 columns

```
# Transformando variáveis categóricas'brand', 'fuel', 'gear' em numéricas
tbDados_Regr = pd.get_dummies(tbDados_Regr, columns=['brand','fuel','gear'],dtype='int64')

# Tratamento da variável 'engine_size' para indicação numérica
```

```
tbDados_Regr['engine_size'] =
LabelEncoder().fit_transform(tbDados_Regr['engine_size'])
tbDados_Regr
```

	year_of_reference	engine_size	year_model	avg_price_brl	brand_Fiat	brand_Ford	brand_GM - Chevrolet	brand_Nissan	brand_Renault	brand_VW - VolksWagen	fuel_Alcohol	fuel_Diesel	fuel_Gasoline	gear_automatic	gear_manual
0	2021.0	0	2002.0	9162.0	0	0	1	0	0	0	0	0	1	0	1
1	2021.0	0	2001.0	8832.0	0	0	1	0	0	0	0	0	1	0	1
2	2021.0	0	2000.0	8388.0	0	0	1	0	0	0	0	0	1	0	1
3	2021.0	0	2000.0	8453.0	0	0	1	0	0	0	1	0	0	0	1
4	2021.0	5	2001.0	12525.0	0	0	1	0	0	0	0	0	1	0	1
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...
202292	2023.0	5	2023.0	86038.0	0	0	0	0	0	1	0	0	1	0	1
202293	2023.0	0	2023.0	95997.0	0	0	0	0	0	1	0	0	1	0	1
202294	2023.0	0	2023.0	87828.0	0	0	0	0	0	1	0	0	1	0	1
202295	2023.0	0	2023.0	80845.0	0	0	0	0	0	1	0	0	1	0	1
202296	2023.0	0	2023.0	74458.0	0	0	0	0	0	1	0	0	1	0	1

202295 rows × 15 columns

```
# Mapa de correlação das variáveis numéricas com variável Target
plt.figure(figsize=(20,10))
sns.heatmap(tbDados_Regr.corr("spearman"), annot = True, cmap="coolwarm")
plt.title("Mapa de Correlação das Variáveis Numéricas\n", fontsize = 15)
plt.show()
```

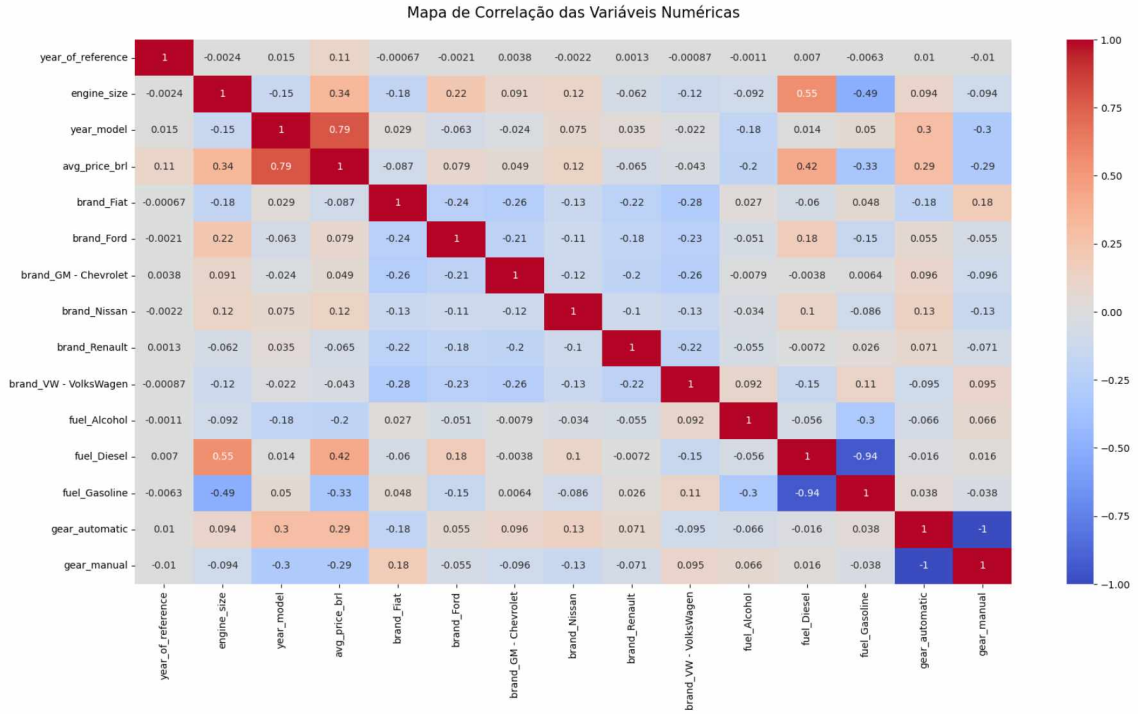

Questão 3.b)

```
# Variável X contém as variáveis numéricas de interesse para a análise,
excluindo a variável target
varX = tbDados_Regr.drop(['avg_price_brl'],axis = 1)
varX.head()
```

	year_of_reference	engine_size	year_model	brand_Fiat	brand_Ford	brand_GM - Chevrolet	brand_Nissan	brand_Renault	brand_VW - VolksWagen	fuel_Alcohol	fuel_Diesel	fuel_Gasoline	gear_automatic	gear_manual
0	2021.0	0	2002.0	0	0	1	0	0	0	0	0	1	0	1
1	2021.0	0	2001.0	0	0	1	0	0	0	0	0	1	0	1
2	2021.0	0	2000.0	0	0	1	0	0	0	0	0	1	0	1
3	2021.0	0	2000.0	0	0	1	0	0	0	1	0	0	0	1
4	2021.0	5	2001.0	0	0	1	0	0	0	0	0	1	0	1

```
# Variável Y contém apenas a variável target - 'avg_price_brl'
varY = tbDados_Regr['avg_price_brl']
varY.head()
0     9162.0
1     8832.0
2     8388.0
3     8453.0
4    12525.0
Name: avg_price_brl, dtype: float64

# Atribuindo 75% dos dados para treinamento e 25% dos dados para testes
X_train, X_test, Y_train, Y_test = train_test_split(varX, varY, test_size =
0.25, random_state = 42)

# Observando os dados de treinamento
print(X_train.shape)
X_train.head(1)
(151721, 14)
```

	year_of_reference	engine_size	year_model	brand_Fiat	brand_Ford	brand_GM - Chevrolet	brand_Nissan	brand_Renault	brand_VW - VolksWagen	fuel_Alcohol	fuel_Diesel	fuel_Gasoline	gear_automatic	gear_manual
156364	2022.0	10	2020.0	1	0	0	0	0	0	0	1	0	0	1

```
# Observando a variável target
Y_test.head()
180633    42595.0
13130     10989.0
163315     9087.0
121464    26965.0
14044     57102.0
Name: avg_price_brl, dtype: float64
```

Questão 3.c)

```
# Treino RandomForest
mdlRanForest = RandomForestRegressor()

# Ajuste do modelo conforme variáveis de treinamento
mdlRanForest.fit(X_train, Y_train)
```


```
# Treino XGBoost
mdlXgboost = XGBRegressor()
```

```
# Ajuste do modelo conforme variáveis de treinamento
mdlXgboost.fit(X_train, Y_train)
```

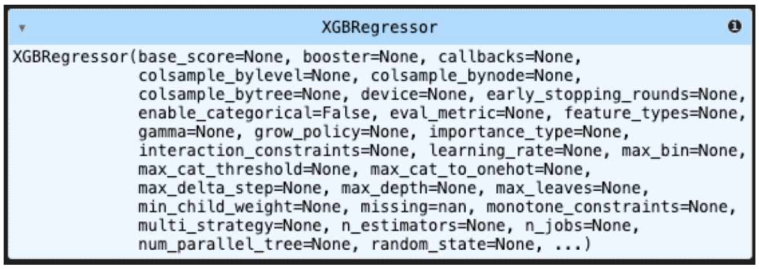

Questão 3.d)

```
# Gravar os valores preditos em variáveis
# Valores preditos em RandomForest com base nos dados de teste
valPredRanForest = mdlRanForest.predict(X_test)
valPredRanForest
array([ 44889.62859266,  12739.80934143,  15295.85822716, ...,
       117329.56881555,  16274.02237751,  21525.00267423])

# Valores preditos em XGBoost com base nos dados de teste
valPredXgboost = mdlXgboost.predict(X_test)
valPredXgboost
array([ 45345.223,  12810.657,  15979.231, ...,
       117479.83 ,  15259.941, 22179.574], dtype=float32)
```

Questão 3.e)

```
# Análise da importância das variáveis em RandomForest para estimativa do
alvo
mdlRanForest.feature_importances_
feature_importancesRF = pd.DataFrame(mdlRanForest.feature_importances_,
index = X_train.columns, columns=['importance']).sort_values('importance',
ascending = False)
feature_importancesRF
```

	importance
engine_size	0.428020
year_model	0.396104
fuel_Diesel	0.076969
gear_automatic	0.021225
gear_manual	0.018628
year_of_reference	0.013558
fuel_Gasoline	0.012433
brand_Nissan	0.011678
brand_VW - VolksWagen	0.011213
brand_GM - Chevrolet	0.002731
brand_Renault	0.002713
brand_Ford	0.002528
brand_Fiat	0.002182
fuel_Alcohol	0.000018

```
# Análise da importância das variáveis em XGBoost para estimativa do alvo
mdlXgboost.feature_importances_
feature_importancesXG = pd.DataFrame(mdlXgboost.feature_importances_, index
=     X_train.columns,     columns=['importance']).sort_values('importance',
ascending = False)
feature_importancesXG
```

	importance
fuel_Diesel	0.427805
engine_size	0.237555
year_model	0.167987
gear_automatic	0.049263
brand_Renault	0.026771
brand_Nissan	0.026539
brand_VW - VolksWagen	0.026310
year_of_reference	0.011607
brand_Fiat	0.010896
brand_GM - Chevrolet	0.007659
brand_Ford	0.005939
fuel_Alcohol	0.000907
fuel_Gasoline	0.000762
gear_manual	0.000000

Questão 3.f)

No modelo de RandomForest as variáveis com maior importância foram o tamanho do motor e o ano do modelo. Essa relevância pode ser observada ao computar com o método feature_importances e também no mapa de correlação de variáveis. Para o XGBoost, as variáveis mais relevantes foram combustível a diesel, tamanho do motor e o ano do modelo.

Questão 3.g)

```
# Escolha do melhor modelo com base nas métricas de avaliação MSE, MAE, R2
# Métrica RandomForest
# Resultado análise MSE em RandomForest
valMSErf = mean_squared_error(Y_test, valPredRanForest)
valMSErf
106634614.2088013

# Resultado análise MAE em RandomForest
valMAErf = mean_absolute_error(Y_test, valPredRanForest)
valMAErf
5599.162102900011

# Resultado análise R2 em RandomForest
valR2rf = r2_score(Y_test, valPredRanForest)
valR2rf
0.9603773993318255
```

```
# Métricas XGBoost
# Resultado análise MSE em XGBoost
valMSExg = mean_squared_error(Y_test, valPredXgboost)
valMSExg
107807654.56567411

# Resultado análise MAE em XGBoost
valMAExg = mean_absolute_error(Y_test, valPredXgboost)
valMAExg
5668.311479710965


# Resultado análise R2 em XGBoost
valR2xg = r2_score(Y_test, valPredXgboost)
valR2xg
0.9599415285784788
```

Questão 3.h)

Analisando as métricas em ambos os modelos, observa-se que RandomForest e XGBoost tiveram um bom desempenho. No entanto, o melhor modelo foi o do Random Forest que atingiu coeficiente de determinação de 0.96 e menores valores para MSE e MAE.

APÊNDICE 3 – LINGUAGEM R

A – ENUNCIADO

1 Pesquisa com Dados de Satélite (Satellite)

O banco de dados consiste nos valores multiespectrais de pixels em vizinhanças 3x3 em uma imagem de satélite, e na classificação associada ao pixel central em cada vizinhança. O objetivo é prever esta classificação, dados os valores multiespectrais.

Um quadro de imagens do Satélite Landsat com MSS (*Multispectral Scanner System*) consiste em quatro imagens digitais da mesma cena em diferentes bandas espectrais. Duas delas estão na região visível (correspondendo aproximadamente às regiões verde e vermelha do espectro visível) e duas no infravermelho (próximo). Cada pixel é uma palavra binária de 8 bits, com 0 correspondendo a preto e 255 a branco. A resolução espacial de um pixel é de cerca de 80m x 80m. Cada imagem contém 2340 x 3380 desses pixels. O banco de dados é uma subárea (minúscula) de uma cena, consistindo de 82 x 100 pixels. Cada linha de dados corresponde a uma vizinhança quadrada de pixels 3x3 completamente contida dentro da subárea 82x100. Cada linha contém os valores de pixel nas quatro bandas espectrais (convertidas em ASCII) de cada um dos 9 pixels na vizinhança de 3x3 e um número indicando o rótulo de classificação do pixel central.

As classes são: solo vermelho, colheita de algodão, solo cinza, solo cinza úmido, restolho de vegetação, solo cinza muito úmido.

Os dados estão em ordem aleatória e certas linhas de dados foram removidas, portanto você não pode reconstruir a imagem original desse conjunto de dados. Em cada linha de dados, os quatro valores espectrais para o pixel superior esquerdo são dados primeiro, seguidos pelos quatro valores espectrais para o pixel superior central e, em seguida, para o pixel superior direito, e assim por diante, com os pixels lidos em sequência, da esquerda para a direita e de cima para baixo. Assim, os quatro valores espectrais para o pixel central são dados pelos atributos 17, 18, 19 e 20. Se você quiser, pode usar apenas esses quatro atributos, ignorando os outros. Isso evita o problema que surge quando uma vizinhança 3x3 atravessa um limite.

O banco de dados se encontra no pacote **mlbench** e é completo (não possui dados faltantes).

Tarefas:

1. Carregue a base de dados Satellite
2. Crie partições contendo 80% para treino e 20% para teste
3. Treine modelos RandomForest, SVM e RNA para predição destes dados.
4. Escolha o melhor modelo com base em suas matrizes de confusão.
5. Indique qual modelo dá o melhor o resultado e a métrica utilizada

2 Estimativa de Volumes de Árvores

Modelos de aprendizado de máquina são bastante usados na área da engenharia florestal (mensuração florestal) para, por exemplo, estimar o volume de madeira de árvores sem ser necessário abatê-las.

O processo é feito pela coleta de dados (dados observados) através do abate de algumas árvores, onde sua altura, diâmetro na altura do peito (dap), etc, são medidos de forma exata. Com estes dados, treina-se um modelo de AM que pode estimar o volume de outras árvores da população.

Os modelos, chamados alométricos, são usados na área há muitos anos e são baseados em regressão (linear ou não) para encontrar uma equação que descreve os dados. Por exemplo, o modelo de Spurr é dado por:

$$\textbf{Volume} = b0 + b1 * dap^2 * Ht$$

Onde dap é o diâmetro na altura do peito (1,3metros), Ht é a altura total. Tem-se vários modelos alométricos, cada um com uma determinada característica, parâmetros, etc. Um modelo de regressão envolve aplicar os dados observados e encontrar b0 e b1 no modelo apresentado, gerando assim uma equação que pode ser usada para prever o volume de outras árvores.

Dado o arquivo **Volumes.csv**, que contém os dados de observação, escolha um modelo de aprendizado de máquina com a melhor estimativa, a partir da estatística de correlação.

Tarefas

1. Carregar o arquivo Volumes.csv (http://www.razer.net.br/datasets/Volumes.csv)
2. Eliminar a coluna NR, que só apresenta um número sequencial
3. Criar partição de dados: treinamento 80%, teste 20%
4. Usando o pacote "caret", treinar os modelos: Random Forest (rf), SVM (svmRadial), Redes Neurais (neuralnet) e o modelo alométrico de SPURR

    - O modelo alométrico é dado por: Volume = b0 + b1 * dap^2 * Ht

      alom <- nls(VOL ~ b0 + b1*DAP*DAP*HT, dados, start=list(b0=0.5, b1=0.5))

5. Efetue as predições nos dados de teste
6. Crie suas próprias funções (UDF) e calcule as seguintes métricas entre a predição e os dados observados

    - Coeficiente de determinação: R^2

$$R^2 = 1 - \frac{\sum_{i=1}^{n} (y_i - \widehat{y_i})^2}{\sum_{i=1}^{n} (y_i - \bar{y})^2}$$

onde y_i é o valor observado, $\widehat{y_i}$ é o valor predito e $\bar{y}$ é a média dos valores y_i observados. Quanto mais perto de 1 melhor é o modelo;

- Erro padrão da estimativa: S_{yx}

$$S_{yx} = \sqrt{\frac{\sum_{i=1}^{n} (y_i - \widehat{y_i})^2}{n-2}}$$

esta métrica indica erro, portanto quanto mais perto de 0 melhor é o modelo;

- Syx%

$$S_{yx}\% = \frac{S_{yx}}{\bar{y}} * 100$$

esta métrica indica porcentagem de erro, portanto quanto mais perto de 0 melhor é o modelo;

7. Escolha o melhor modelo.

B – RESOLUÇÃO

1 Pesquisa com Dados de Satélite

Entrada e saída de comandos:

```
> # instalação e carregamento de pacotes necessários
> install.packages('e1071')
trying URL 'https://cran.rstudio.com/bin/macosx/big-sur-x86_64/contrib/4.3/e1071_1.7-14.tgz'
Content type 'application/x-gzip' length 683532 bytes (667 KB)
==================================================
downloaded 667 KB

The downloaded binary packages are in
/var/folders/8r/b5l78l452x7gp_wwtm8n9zvc0000gn/T//Rtmp4EsWHz/downloaded_packages
> install.packages('randomForest')
trying URL 'https://cran.rstudio.com/bin/macosx/big-sur-x86_64/contrib/4.3/randomForest_4.7-1.1.tgz'
Content type 'application/x-gzip' length 269721 bytes (263 KB)
==================================================
downloaded 263 KB

The downloaded binary packages are in
/var/folders/8r/b5l78l452x7gp_wwtm8n9zvc0000gn/T//Rtmp4EsWHz/downloaded_packages
```

```
> install.packages('kernlab')
trying           URL           'https://cran.rstudio.com/bin/macosx/big-sur-
x86_64/contrib/4.3/kernlab_0.9-32.tgz'
Content type 'application/x-gzip' length 2526541 bytes (2.4 MB)
==================================================
downloaded 2.4 MB

The downloaded binary packages are in
/var/folders/8r/b5l78l452x7gp_wwtm8n9zvc0000gn/T//Rtmp4EsWHz/downloaded_pac
kages
> install.packages('mlbench')
trying           URL           'https://cran.rstudio.com/bin/macosx/big-sur-
x86_64/contrib/4.3/mlbench_2.1-3.1.tgz'
Content type 'application/x-gzip' length 1052825 bytes (1.0 MB)
==================================================
downloaded 1.0 MB

The downloaded binary packages are in
/var/folders/8r/b5l78l452x7gp_wwtm8n9zvc0000gn/T//Rtmp4EsWHz/downloaded_pac
kages
> install.packages('caret')
Error in install.packages : Updating loaded packages

> install.packages("caret")
trying           URL           'https://cran.rstudio.com/bin/macosx/big-sur-
x86_64/contrib/4.3/caret_6.0-94.tgz'
Content type 'application/x-gzip' length 3587235 bytes (3.4 MB)
==================================================
downloaded 3.4 MB

The downloaded binary packages are in
/var/folders/8r/b5l78l452x7gp_wwtm8n9zvc0000gn/T//Rtmpde2FdR/downloaded_pac
kages
> library('mlbench')
> library('caret')
Loading required package: ggplot2
Loading required package: lattice
> # carregando a base de dados Satellite
> set.seed(123)
> data("Satellite")
> # construindo dataframe apenas com dados de interesse para classificação
```

```
> database <- data.frame(Satellite[17:20])
> database$classes <- Satellite$classes
> # criando partições de treino e teste
> indices <- createDataPartition(database$classes,p = 0.8,list = FALSE)
> treino <- database[indices,]
> teste <- database[-indices,]
> # randomForest
> rf <- caret::train(classes~., data=treino, method='rf')
> # svm
> svm <- caret::train(classes~.,data=treino, method='svmRadial')
> # rna
> rna <- caret::train(classes~., data=treino, method='nnet', trace=FALSE)
> # randomForest
> predicoes.rf <- predict(rf,teste)
> #svm
> predicoes.svm <- predict(svm,teste)
> #rna
> predicoes.rna <- predict(rna,teste)
> # randomForest
> confusionMatrix(predicoes.rf, teste$classes)
Confusion Matrix and Statistics

                    Reference
Prediction           red soil cotton crop grey soil damp grey soil vegetation stubble
  red soil                294           0         1              1                10
  cotton crop               0         128         0              0                 1
  grey soil                 6           0       247             27                 2
  damp grey soil            0           0        16             65                 1
  vegetation stubble        6          12         0              1               110
  very damp grey soil       0           0         7             31                17
                    Reference
Prediction           very damp grey soil
  red soil                             0
  cotton crop                          0
  grey soil                           11
  damp grey soil                      34
  vegetation stubble                   6
  very damp grey soil                250

Overall Statistics

               Accuracy : 0.852
                 95% CI : (0.8314, 0.871)
    No Information Rate : 0.2383
    P-Value [Acc > NIR] : < 2.2e-16

                  Kappa : 0.8169

 Mcnemar's Test P-Value : NA

Statistics by Class:

                     Class: red soil Class: cotton crop Class: grey soil
Sensitivity                   0.9608            0.91429           0.9114
Specificity                   0.9877            0.99913           0.9546
Pos Pred Value                0.9608            0.99225           0.8430
Neg Pred Value                0.9877            0.98961           0.9758
Prevalence                    0.2383            0.10903           0.2111
Detection Rate                0.2290            0.09969           0.1924
Detection Prevalence          0.2383            0.10047           0.2282
Balanced Accuracy             0.9743            0.95671           0.9330
```

```
                     Class: damp grey soil Class: vegetation stubble
Sensitivity                        0.52000                    0.78014
Specificity                        0.95600                    0.97813
Pos Pred Value                     0.56034                    0.81481
Neg Pred Value                     0.94863                    0.97302
Prevalence                         0.09735                    0.10981
Detection Rate                     0.05062                    0.08567
Detection Prevalence               0.09034                    0.10514
Balanced Accuracy                  0.73800                    0.87913
                     Class: very damp grey soil
Sensitivity                            0.8306
Specificity                            0.9440
Pos Pred Value                         0.8197
Neg Pred Value                         0.9479
Prevalence                             0.2344
Detection Rate                         0.1947
Detection Prevalence                   0.2375
Balanced Accuracy                      0.8873
```

```
> # svm
> confusionMatrix(predicoes.svm, teste$classes)
Confusion Matrix and Statistics

                    Reference
Prediction           red soil cotton crop grey soil damp grey soil vegetation stubble
  red soil                297           0         1              1                14
  cotton crop               0         127         0              0                 0
  grey soil                 6           0       259             32                 1
  damp grey soil            0           0        10             66                 0
  vegetation stubble        3          13         0              1               102
  very damp grey soil       0           0         1             25                24
                    Reference
Prediction           very damp grey soil
  red soil                             0
  cotton crop                          0
  grey soil                           12
  damp grey soil                      32
  vegetation stubble                   7
  very damp grey soil                250

Overall Statistics

               Accuracy : 0.8575
                 95% CI : (0.8371, 0.8762)
    No Information Rate : 0.2383
    P-Value [Acc > NIR] : < 2.2e-16

                  Kappa : 0.8233

 Mcnemar's Test P-Value : NA

Statistics by Class:

                     Class: red soil Class: cotton crop Class: grey soil
Sensitivity                   0.9706            0.90714           0.9557
Specificity                   0.9836            1.00000           0.9497
Pos Pred Value                0.9489            1.00000           0.8355
Neg Pred Value                0.9907            0.98876           0.9877
Prevalence                    0.2383            0.10903           0.2111
Detection Rate                0.2313            0.09891           0.2017
Detection Prevalence          0.2438            0.09891           0.2414
Balanced Accuracy             0.9771            0.95357           0.9527
                     Class: damp grey soil Class: vegetation stubble
Sensitivity                        0.52800                    0.72340
Specificity                        0.96376                    0.97900
Pos Pred Value                     0.61111                    0.80952
Neg Pred Value                     0.94983                    0.96632
Prevalence                         0.09735                    0.10981
Detection Rate                     0.05140                    0.07944
Detection Prevalence               0.08411                    0.09813
Balanced Accuracy                  0.74588                    0.85120
                     Class: very damp grey soil
Sensitivity                            0.8306
Specificity                            0.9491
Pos Pred Value                         0.8333
Neg Pred Value                         0.9482
Prevalence                             0.2344
Detection Rate                         0.1947
Detection Prevalence                   0.2336
Balanced Accuracy                      0.8899
```

```
> # rna
> confusionMatrix(predicoes.rna, teste$classes)
Confusion Matrix and Statistics

                    Reference
Prediction           red soil cotton crop grey soil damp grey soil vegetation stubble
  red soil                297           3         1              4                16
  cotton crop               0         116         0              0                 0
  grey soil                 5           0       265             83                 2
  damp grey soil            0           0         0              0                 0
  vegetation stubble        3          18         0              0                91
  very damp grey soil       1           3         5             38                32
                    Reference
Prediction           very damp grey soil
  red soil                             1
  cotton crop                          0
  grey soil                           43
  damp grey soil                       0
  vegetation stubble                   8
  very damp grey soil                249

Overall Statistics

               Accuracy : 0.7928
                 95% CI : (0.7696, 0.8147)
    No Information Rate : 0.2383
    P-Value [Acc > NIR] : < 2.2e-16

                  Kappa : 0.7394

 Mcnemar's Test P-Value : NA

Statistics by Class:

                     Class: red soil Class: cotton crop Class: grey soil
Sensitivity                   0.9706            0.82857           0.9779
Specificity                   0.9744            1.00000           0.8687
Pos Pred Value                0.9224            1.00000           0.6658
Neg Pred Value                0.9906            0.97945           0.9932
Prevalence                    0.2383            0.10903           0.2111
Detection Rate                0.2313            0.09034           0.2064
Detection Prevalence          0.2508            0.09034           0.3100
Balanced Accuracy             0.9725            0.91429           0.9233
                     Class: damp grey soil Class: vegetation stubble
Sensitivity                        0.00000                   0.64539
Specificity                        1.00000                   0.97463
Pos Pred Value                         NaN                   0.75833
Neg Pred Value                     0.90265                   0.95704
Prevalence                         0.09735                   0.10981
Detection Rate                     0.00000                   0.07087
Detection Prevalence               0.00000                   0.09346
Balanced Accuracy                  0.50000                   0.81001
                     Class: very damp grey soil
Sensitivity                              0.8272
Specificity                              0.9196
Pos Pred Value                           0.7591
Neg Pred Value                           0.9456
Prevalence                               0.2344
Detection Rate                           0.1939
Detection Prevalence                     0.2555
Balanced Accuracy                        0.8734
```

Comparação Matriz de Confusão dos Modelos:

```
> confusionMatrix(predicoes.rf, teste$classes)
```

Accuracy : 0.852

95% CI : (0.8314, 0.871)

No Information Rate : 0.2383

P-Value [Acc > NIR] : < 2.2e-16

```
> confusionMatrix(predicoes.svm, teste$classes)
```

Accuracy : 0.8575

95% CI : (0.8371, 0.8762)

No Information Rate : 0.2383

P-Value [Acc > NIR] : < 2.2e-16

```
> confusionMatrix(predicoes.rna, teste$classes)
Accuracy : 0.7928
95% CI : (0.7696, 0.8147)
No Information Rate : 0.2383
P-Value [Acc > NIR] : < 2.2e-16
```

Em problemas de classificação, uma das métricas de referência para avaliar a performance de modelos é a acurácia que indica a proporção de instâncias classificadas corretamente pelo modelo em relação ao total de previsões. Em virtude disso, o modelo escolhido foi o de svm, que obteve 0.8575 de acurácia, a melhor dentre os três modelos.

2 Estimativa de Volume de Árvores

Entrada e saída de comandos:

```
> # instalação e carregamento de pacotes necessários
> install.packages('e1071')
trying URL 'https://cran.rstudio.com/bin/macosx/big-sur-x86_64/contrib/4.3/e1071_1.7-14.tgz'
Content type 'application/x-gzip' length 683532 bytes (667 KB)
==================================================
downloaded 667 KB

The downloaded binary packages are in
/var/folders/8r/b5l78l452x7gp_wwtm8n9zvc0000gn/T//RtmpQgB6zZ/downloaded_packages
> install.packages('randomForest')
trying URL 'https://cran.rstudio.com/bin/macosx/big-sur-x86_64/contrib/4.3/randomForest_4.7-1.1.tgz'
Content type 'application/x-gzip' length 269721 bytes (263 KB)
==================================================
downloaded 263 KB

The downloaded binary packages are in
/var/folders/8r/b5l78l452x7gp_wwtm8n9zvc0000gn/T//RtmpQgB6zZ/downloaded_packages
> install.packages('kernlab')
trying URL 'https://cran.rstudio.com/bin/macosx/big-sur-x86_64/contrib/4.3/kernlab_0.9-32.tgz'
Content type 'application/x-gzip' length 2526541 bytes (2.4 MB)
==================================================
downloaded 2.4 MB
```

```
The downloaded binary packages are in
/var/folders/8r/b5l78l452x7gp_wwtm8n9zvc0000gn/T//RtmpQgB6zZ/downloaded_pac
kages
> install.packages('caret')
Error in install.packages : Updating loaded packages

> install.packages("caret")
trying           URL           'https://cran.rstudio.com/bin/macosx/big-sur-
x86_64/contrib/4.3/caret_6.0-94.tgz'
Content type 'application/x-gzip' length 3587235 bytes (3.4 MB)
==================================================
downloaded 3.4 MB

The downloaded binary packages are in
/var/folders/8r/b5l78l452x7gp_wwtm8n9zvc0000gn/T//RtmpSW76Bn/downloaded_pac
kages
> library('caret')
Loading required package: ggplot2
Loading required package: lattice
> # carregar arquivo de volumes
> set.seed(123)
> data <- read.csv2("http://www.razer.net.br/datasets/Volumes.csv")
> # eliminando coluna NR
> data$NR <- NULL
> indices <- createDataPartition(data$VOL, p=0.8, list=FALSE)
> treino <- data[indices,]
> teste <- data[-indices,]
> # randomForest
> rf <- caret::train(VOL~.,data=treino,method='rf')
note: only 2 unique complexity parameters in default grid. Truncating the
grid to 2 .

> # svm
> svm <- caret::train(VOL~., data=treino, method='svmRadial')
> # rna
> rna <- caret::train(VOL~., data=treino, method='nnet', trace=FALSE)
Warning message:
In nominalTrainWorkflow(x = x, y = y, wts = weights, info = trainInfo,  :
  There were missing values in resampled performance measures.
> # alométrico
```

```
> alom <- nls(VOL ~b0 + b1 * DAP*DAP*HT, data=treino, start=list(b0=0.5,
b1=0.5))
> #randomForest
> predicoes.rf <- predict(rf,teste)
> #svm
> predicoes.svm <- predict(svm,teste)
> #rna
> predicoes.rna <- predict(rna,teste)
> #alométrico
> predicoes.alom <- predict(alom,teste)
> # UDF
> # coeficiente de determinação
> coef_det <- function(obs, preds){
+   sum_pos <- sum((obs - preds) ^ 2)
+   sum_neg <- sum ((obs - mean(obs)) ^2)
+   result <- 1 - (sum_pos / sum_neg)
+   return(result)
+ }
> # erro padrão da estimativa
> standard_error <- function(obs, preds){
+   size <- length(obs)
+   sum_pos <- sum((obs - preds) ^ 2)
+   result = sqrt((sum_pos / (size - 2)))
+   return(result)
+ }
> percentage_error <- function(obs,preds){
+   size <- length(obs)
+   sum_pos <- sum((obs - preds) ^ 2)
+   partial_result = sqrt((sum_pos / (size - 2)))
+   result <- (partial_result/mean(obs)) * 100
+ }
> #randomForest
> rf.coef <- coef_det(teste$VOL, predicoes.rf)
> rf.error <- standard_error(teste$VOL, predicoes.rf)
> rf.percentage_error <- percentage_error(teste$VOL, predicoes.rf)
> # svm
> svm.coef <- coef_det(teste$VOL, predicoes.svm)
> svm.error <- standard_error(teste$VOL, predicoes.svm)
> svm.percentage_error <- percentage_error(teste$VOL, predicoes.svm)
> # rna
> rna.coef <- coef_det(teste$VOL, predicoes.rna)
```

```
> rna.error <- standard_error(teste$VOL, predicoes.rna)
> rna.percentage_error <- percentage_error(teste$VOL, predicoes.rna)
> # alométrico
> alom.coef <- coef_det(teste$VOL, predicoes.alom)
> alom.error <- standard_error(teste$VOL, predicoes.alom)
> alom.percentage_error <- percentage_error(teste$VOL, predicoes.alom)
>
> rf.coef
[1] 0.8486654
> svm.coef
[1] 0.7899082
> rna.coef
[1] -0.8207433
> alom.coef
[1] 0.8694429
> rf.error
[1] 0.156604
> svm.error
[1] 0.1845178
> rna.error
[1] 0.5431978
> alom.error
[1] 0.1454567
> rf.percentage_error
[1] 11.63489
> svm.percentage_error
[1] 13.70874
> rna.percentage_error
[1] 40.35687
> alom.percentage_error
[1] 10.8067
```

Após aplicação dos cálculos obteve-se os seguintes resultados:

	RandomForest	SVM	RNA	Alométrico
Coeficiente de determinação R^2	0.8486654	0.7899082	-0.8207433	0.8694429
Erro padrão da estimativa S_{yx}	0.156604	0.1845178	0.5431978	0.1454567
Porcentagem de erro S_{yx}%	11.63489	13.70874	40.35687	10.8067

Levando em consideração o coeficiente de determinação R^2, o melhor modelo foi o Alométrico, visto que é o que mais se aproxima de 1. A estimativa de erro padrão também foi a menor neste modelo.

APÊNDICE 4 – ESTATÍSTICA APLICADA I

A – ENUNCIADO

1) Gráficos e tabelas

(15 pontos) Elaborar os gráficos box-plot e histograma das variáveis “age” (idade da esposa) e “husage” (idade do marido) e comparar os resultados

(15 pontos) Elaborar a tabela de frequencias das variáveis “age” (idade da esposa) e “husage” (idade do marido) e comparar os resultados

2) Medidas de posição e dispersão

(15 pontos) Calcular a média, mediana e moda das variáveis “age” (idade da esposa) e “husage” (idade do marido) e comparar os resultados

(15 pontos) Calcular a variância, desvio padrão e coeficiente de variação das variáveis “age” (idade da esposa) e “husage” (idade do marido) e comparar os resultados

3) Testes paramétricos ou não paramétricos

(40 pontos) Testar se as médias (se você escolher o teste paramétrico) ou as medianas (se você escolher o teste não paramétrico) das variáveis “age” (idade da esposa) e “husage” (idade do marido) são iguais, construir os intervalos de confiança e comparar os resultados.

Obs:

Você deve fazer os testes necessários (e mostra-los no documento pdf) para saber se você deve usar o unpaired test (paramétrico) ou o teste U de Mann-Whitney (não paramétrico), justifique sua resposta sobre a escolha.

Lembre-se de que os intervalos de confiança já são mostrados nos resultados dos testes citados no item 1 acima.

B – RESOLUÇÃO

1 Gráfico e tabelas

a) Elaborar os gráficos box-plot e histograma das variáveis "age" (idade da esposa) e "husage" (idade do marido) e comparar os resultados:

```
# Instalação de pacotes e upload/leitura base de dados:
install.packages("car")
install.packages("dplyr")
library("car")
library(dplyr)
```

```
load("salarios.RData")

# Gerar gráfico box-plot com idades das esposas e dos maridos:
ages_list <- list(salarios$age, salarios$husage)
names(ages_list) <- c("Esposas", "Maridos")
par(mfrow=c(1,1),mgp=c(3,2,0))
boxplot(ages_list, col="#69b3a2", ylab="Idade", main="Gráfico Box-Plot das
Idades")
```

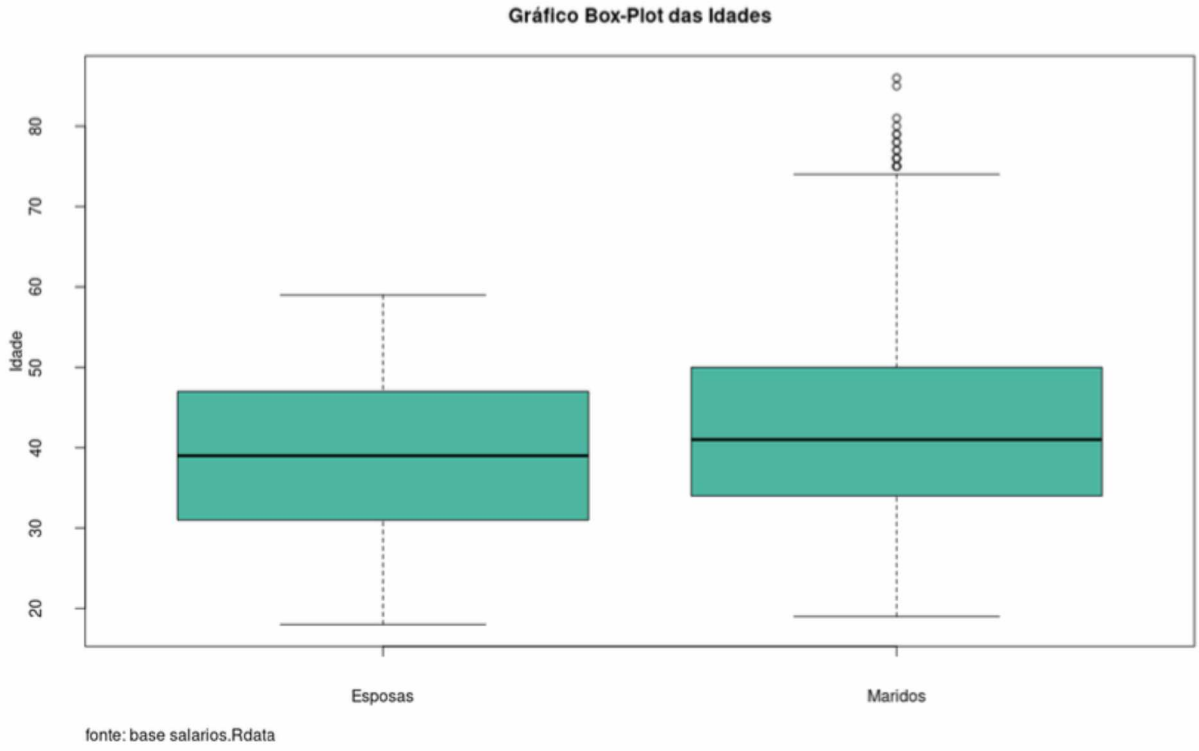

fonte: base salarios.Rdata

```
# Gerar histograma com idades das esposas e dos maridos:
hist(x = salarios$age,xlab = 'Idade das Esposas',ylab = 'Frequência',
col="#69b3a2",
main="Histograma Idade das Esposas")
hist(x=salarios$husage,xlab='Idade dos Maridos',
ylab='Frequência',main="Histograma
Idade dos Maridos",col="#69b3a2")
```

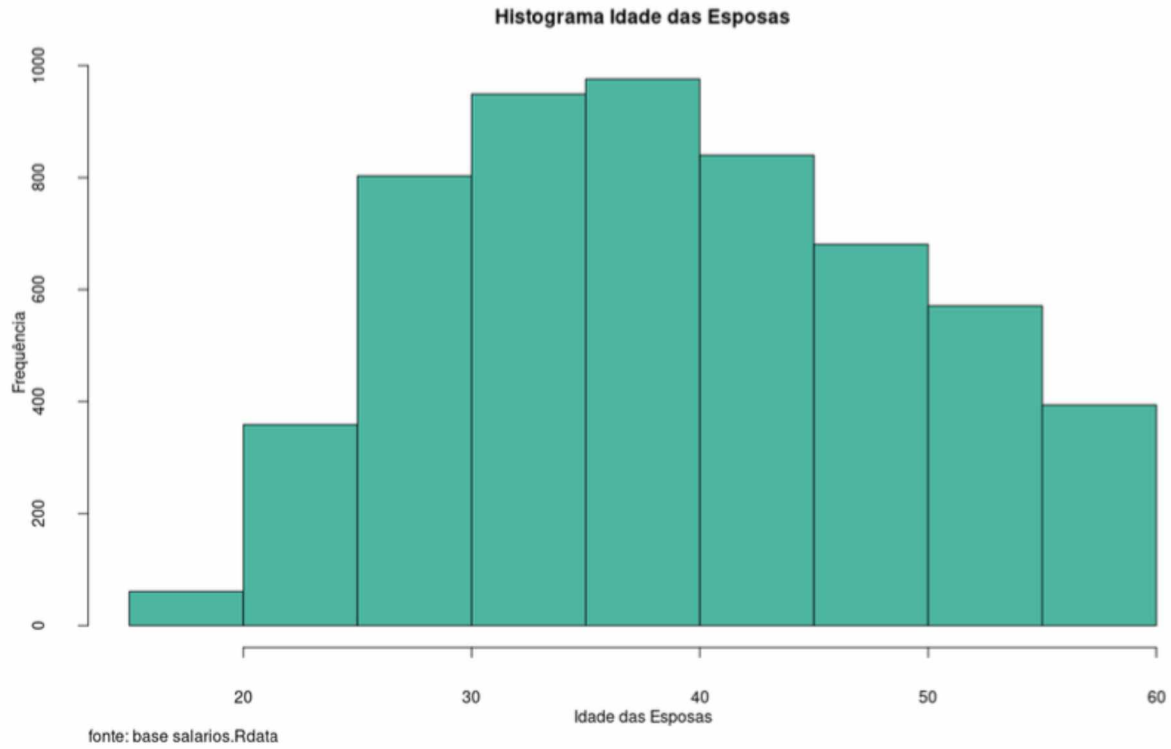

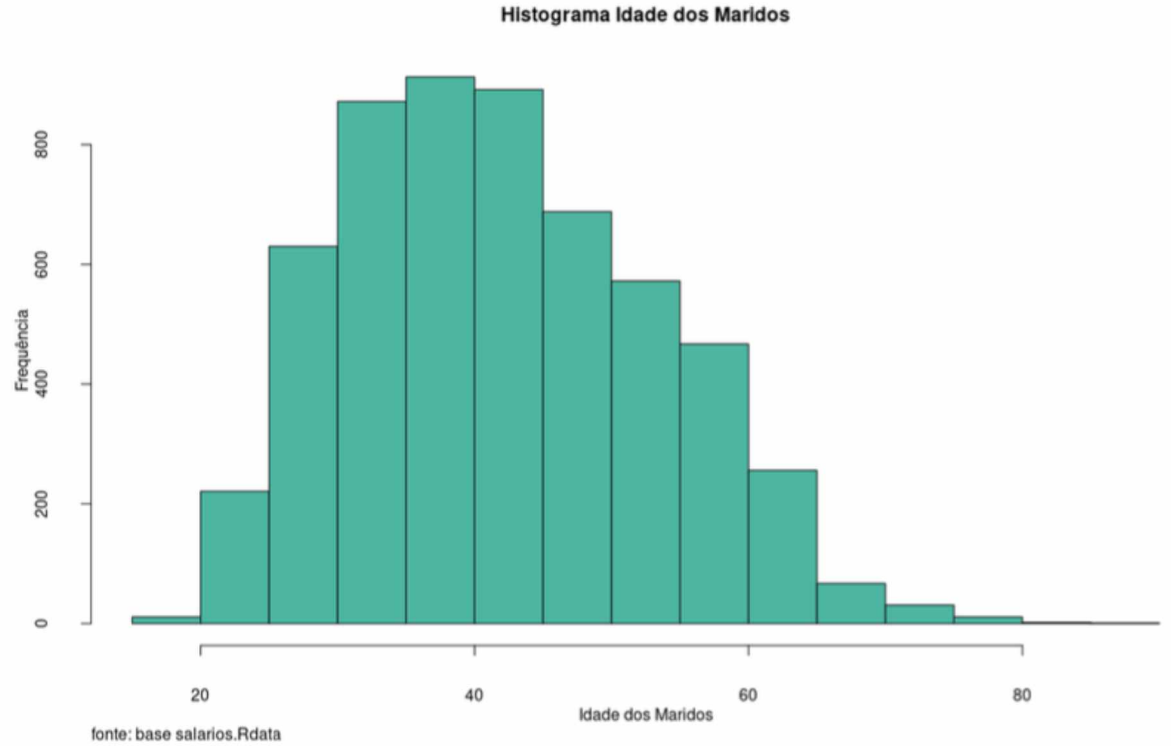


```
# Complementando com a comparação das informações sumárias:
summary(salarios$age)
Min. 1st Qu. Median Mean 3rd Qu. Max.
18.00 31.00 39.00 39.43 47.00 59.00
```

```
summary(salarios$husage)
Min. 1st Qu. Median Mean 3rd Qu. Max.
19.00 34.00 41.00 42.45 50.00 86.00
```

Conclusão:

Os maridos possuem idade média superior ao das esposas e tendem a ter mais idade do que elas. No entanto, a diferença entre as médias e mediana não é expressiva entre ambos. Algumas observações na amostra analisada indicam outliers nas idades dos maridos que afetam a média e, em menor grau, poderiam afetar a mediana deste grupo.

b) Elaborar a tabela de frequências das variáveis "age" (idade da esposa) e "husage" (idade do marido) e comparar os resultados:

```
# Instalação do pacote necessário:
install.packages("fdth")
library(fdth)

# Gerar tabela de frequência com as idades das esposas:
print(fdt(salarios$age))
```

Class limits	f	rf	rf(%)	cf	cf(%)
[17.82,20.804)	61	0.01	1.08	61	1.08
[20.804,23.787)	161	0.03	2.86	222	3.94
[23.787,26.771)	312	0.06	5.54	534	9.48
[26.771,29.754)	505	0.09	8.96	1039	18.44
[29.754,32.738)	562	0.10	9.98	1601	28.42
[32.738,35.721)	571	0.10	10.13	2172	38.55
[35.721,38.705)	624	0.11	11.08	2796	49.63
[38.705,41.689)	510	0.09	9.05	3306	58.68
[41.689,44.672)	542	0.10	9.62	3848	68.30
[44.672,47.656)	432	0.08	7.67	4280	75.97
[47.656,50.639)	389	0.07	6.90	4669	82.87
[50.639,53.623)	358	0.06	6.35	5027	89.23
[53.623,56.606)	304	0.05	5.40	5331	94.62
[56.606,59.59)	303	0.05	5.38	5634	100.00

```
# Gerar tabela de frequência com as idades dos maridos:
print(fdt(salarios$husage))
```

Class limits	f	rf	rf(%)	cf	cf(%)
[18.81,23.671)	102	0.02	1.81	102	1.81
[23.671,28.531)	466	0.08	8.27	568	10.08
[28.531,33.392)	809	0.14	14.36	1377	24.44
[33.392,38.253)	895	0.16	15.89	2272	40.33
[38.253,43.114)	917	0.16	16.28	3189	56.60
[43.114,47.974)	629	0.11	11.16	3818	67.77
[47.974,52.835)	649	0.12	11.52	4467	79.29
[52.835,57.696)	541	0.10	9.60	5008	88.89
[57.696,62.556)	394	0.07	6.99	5402	95.88
[62.556,67.417)	152	0.03	2.70	5554	98.58
[67.417,72.278)	51	0.01	0.91	5605	99.49
[72.278,77.139)	21	0.00	0.37	5626	99.86
[77.139,81.999)	6	0.00	0.11	5632	99.96
[81.999,86.86)	2	0.00	0.04	5634	100.00

Conclusão:

Comparando os resultados de ambas tabelas pode-se obter algumas conclusões:

• Observando-se a tabela de frequências das idades das esposas, percebe-se que a frequência maior está entre as idades de 32 a 39 anos. Já a maior frequência dos maridos está entre 28 e 43 anos. Algumas observações referentes aos maridos indicam que pouco mais de 4% deles possuem idade superior a 60 anos, idade esta inferior a máxima idade observada na amostra referente as esposas.

2 Medidas de posição e dispersão

a) Calcular a média, mediana e moda das variáveis "age" (idade da esposa) e "husage" (idade do marido) e comparar os resultados:

```
# Calcular a média da idade das esposas:
mean(salarios$age)
[1] 39.42758

# Calcular a média da idade dos maridos:
mean(salarios$husage)
[1] 42.45296

# Calcular a mediana da idade das esposas:
median(salarios$age)
[1] 39
```

```
# Calcular a mediana da idade das esposas:
median(salarios$husage)
[1] 41

# Calcular as modas das esposas:
table(salarios$age)
subset(table(salarios$age), table(salarios$age) == max(table(salarios$age)))
37
217

# Calcular as modas dos maridos:
table(salarios$husage)
subset(table(salarios$husage),          table(salarios$husage)          ==
max(table(salarios$husage)))
44
201
```

Tabela resumo:

Item / Grupo	Média	Mediana	Modal	
			Idade	Frequência
Esposas	39.42758	39	37	217
Maridos	42.45296	41	44	201

Conclusão:

• A média das idades dos maridos é 7.67 % maior que a das esposas;
• A mediana das idades dos maridos é 5.13 % maior que a das esposas;
• A moda das idades dos maridos é 18.92 % maior que a das esposas;
• Os resultados indicam que as esposas são, de modo geral, mais jovens que os homens, muito embora a diferença entre ambos os gupos seja pequena;
• Os valores de média e mediana são próximos entre as duas variáveis.

b) Calcular a variância, desvio padrão e coeficiente de variação das variáveis "age" (idade da esposa) e "husage" (idade do marido) e comparar os resultados:

```
# Calcular a variância da idade das esposas:
var(salarios$age)
[1] 99.75234

# Calcular a variância da idade dos maridos:
var(salarios$husage)
[1] 126.0717
```

```
# Calcular o desvio padrão das idades das esposas:
sd(salarios$age)
[1] 9.98761

# Calcular o desvio padrão das idades dos maridos:
sd(salarios$husage)
[1] 11.22817

# Calcular o coeficiente de variação da idades das esposas:
(sd(salarios$age)/mean(salarios$age))*100
[1] 25.33153

# Calcular o coeficiente de variação da idades das esposas:
(sd(salarios$husage)/mean(salarios$husage))*100
[1] 26.44849
```

Tabela resumo:

Item de Análise	Esposas	Maridos
Variância	99.75234	126.0717
Desvio padrão	9.98761	11.22817
Coeficiente de variação	25.33153	26.44849

Conclusão:

• A variância das idades dos maridos é 1.26 % maior que a das esposas;

• O desvio padrão das idades dos maridos é 1.12 % maior que a das esposas;

• Os resultados de variância apresentam uma maior distância da idade dos maridos em referência a média padrão deste grupo;

• Comparando os resultados de desvio padrão, as idades dos maridos possuem desvio também maior em relação ao desvio padrão das esposas;

• Com base nos valores de coeficiente de variação e utilizando a "regra de bolso" para análise desse dado, podemos assumir que há uma dispersão média tanto para as idades dos maridos (cv de 26%), quanto das esposas (cv de 25%).

3 Testes paramétricos ou não paramétricos

a) Testar se as médias (paramétrico) ou as medianas (não paramétrico) das variáveis "age" (idade da esposa) e "husage" (idade do marido) são iguais, construir os intervalos de confiança e comparar os resultados:

```
# Checar condições preliminares para decidir tipo de teste
# Amostras independentes, normalidade e homogeneidade
# das variâncias entre grupos
# Premissa 1: As duas amostras são independentes?
```

```
# Sim, pois as idades das esposas e maridos não estão relacionados e
# não se trata de uma amostra ou grupos emparelhados.
# Premissa 2: Os dados de cada amostra/grupo possuem distribuição
# normal?
# Teste de normalidade Kolmogorov-Smirnov com o seguinte
# teste de hipóteses:
# - H0: os dados são normalmente distribuídos
# - Ha: os dados não são normalmente distribuídos
# Bibliotecas necessárias
library(nortest)
library("ggpubr")

# Para evitar notação científica
options(scipen = 999)

# Realizar os testes de Shapiro-Wilk com as seguintes hipóteses:
• H0: Os dados são normalmente distribuídos
• Ha: Os dados não são normalmente distribuídos

with(idades, shapiro.test(idades[grupo == "Marido"]))
Error in shapiro.test(idades[grupo == "Marido"]) :
sample size must be between 3 and 5000

Conclusão:
A amostra não pode ser testada com o método Shapiro-Wilk, devido o método
possuir restrições quanto ao tamanho da amostra; número máximo de até 5000
observações.

# Primeiro vamos fazer o teste de normalidade Kolmogorov-Smirnov para a
# idade das esposas
wife_normality <- lillie.test(salarios$age)
wife_normality

# p-value < 0.05 (valor de 0.00000000000000022), logo não possui
# distribuicao normal
husband_normality <- lillie.test(salarios$husage)
husband_normality

# p-value < 0.05 (valor de 0.00000000000000022), logo não possui
# distribuição normal
# Premissa 3. As duas populações/amostras/grupos possuem
```

```
# homogeneidade das variâncias?
# O teste de hipóteses é:
# H0: As variâncias são estatisticamente iguais(homogêneas)
# HA: As variâncias não são estatisticamente iguais(homogêneas)
# criando dataset para compara idade das esposas da idade dos maridos
idades <- data.frame(group = rep(c("Esposa","Marido"), each =
length(salarios$age)), idades = c(salarios$age,salarios$husage))

# Analisando algumas medidas dos dados
group_by(idades, group) %>%
summarise(count = n(),median = median(idades, na.rm = TRUE),IQR = IQR(idades,
na.rm = TRUE))

# A tibble: 2 × 4
group count median IQR
<chr> <int> <dbl> <dbl>
1 Esposa 5634 39 16
2 Marido 5634 41 16

# Visualizando boxplot
ggboxplot(idades, x = "group", y = "idades",
color = "group", palette=c("#00AFBB", "#E7B800"),
ylab = "Idade", xlab = "Groups")
```

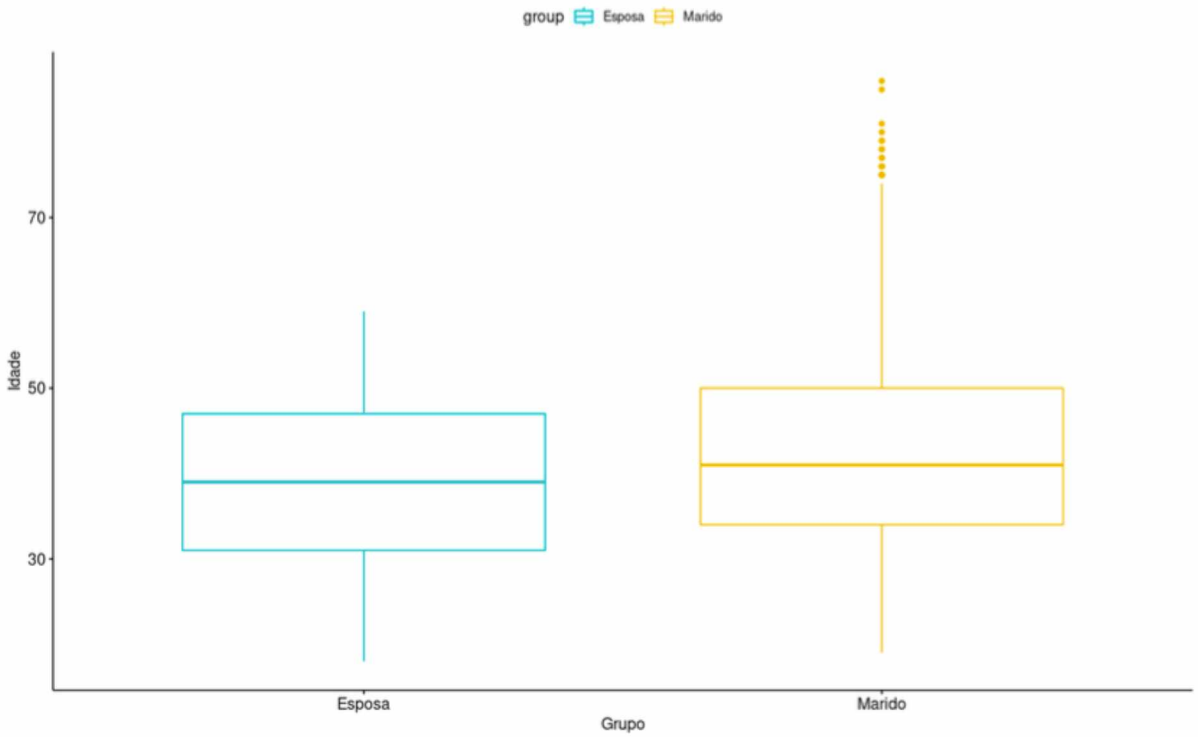

```
# Usaremos o teste F para testar a homogeneidade nas variâncias.
library("sjPlot")
res.ftest <- var.test(idades ~ group, data = idades)
res.ftest

# Obtendo o valor tabelado da distribuição F
qf(0.95, 5633, 5633)
# Temos F=1.04481
# para a outra cauda temos:
1/1.04481
# F = 0.9571118

# Vamos construir o gráfico:
dist_f(f = 1.04481, deg.f1 = 5633, deg.f2 = 5633)
dist_f(f = 0.9571118, deg.f1 = 5633, deg.f2 = 5633)

# O teste de F tem valor crítico entre 0.9571118 e 1.04481 (região de
# não rejeição de H0), os valores acima de 1.04481 e abaixo de
# 0.9571118 estão na região de rejeição de H0.
# O valor da estatística F calculada é de F = 0.79123. Como esse valor
# se encontra na região de rejeição de H0, então rejeitamos a hipótese de
# que as variâncias são  estatisticamente iguais, ou seja, adotamos HA.
# Como não foi verificado normalidade nos dados e nem homogeneidade da
# variância, será adotado um teste não paramétrico e será feito teste para
# verificar se as medianas das variáveis age(Idade Esposas) e husage (Idade
# Maridos) são iguais.

# Teste Não Paramétrico: Teste U de Mann-Whitney
# Hipóteses
# H0: O idade mediana dos homens é igual estatisticamente a idade
# mediana das mulheres;
# Ha: O idade mediana dos homens não é estatisticamente igual a
# idade mediana das mulheres
# Executando teste
res <- wilcox.test(idades ~ group, data = idades,exact = FALSE, conf.int=TRUE)
res

data: idades by group
W = 13619912, p-value < 0.00000000000000022
alternative hypothesis: true location shift is not equal to 0
95 percent confidence interval:
```

```
-3.000024 -2.000033
sample estimates:
difference in location
-2.999966

# O p-value do teste eh 0.00000000000000022 que é menor que o nível de
# significância 0,05. Podemos concluir que a idade mediana dos homens é
# estatisticamente diferente da idade mediana das mulheres, ou seja,
# rejeitamos H0, e adotamos HA. A diferença na localização, a diferença nas
# medianas, é estimada em -2.999966.
# O intervalo de confiança de 95% para a diferença nas localizações é de
# -3.000024 a -2.000033.
```

APÊNDICE 5 – ESTATÍSTICA APLICADA II

A – ENUNCIADO

Regressões Ridge, Lasso e ElasticNet

(100 pontos) Fazer as regressões Ridge, Lasso e ElasticNet com a variável dependente "lwage" (salário-hora da esposa em logaritmo neperiano) e todas as demais variáveis da base de dados são variáveis explicativas (todas essas variáveis tentam explicar o salário-hora da esposa). No pdf você deve colocar a rotina utilizada, mostrar em uma tabela as estatísticas dos modelos (RMSE e R^2) e concluir qual o melhor modelo entre os três, e mostrar o resultado da predição com intervalos de confiança para os seguintes valores:

husage = 40 (anos – idade do marido)
husunion = 0 (marido não possui união estável)
husearns = 600 (US$ renda do marido por semana)
huseduc = 13 (anos de estudo do marido)
husblck = 1 (o marido é preto)
hushisp = 0 (o marido não é hispânico)
hushrs = 40 (horas semanais de trabalho do marido)
kidge6 = 1 (possui filhos maiores de 6 anos)
age = 38 (anos – idade da esposa)
black = 0 (a esposa não é preta)
educ = 13 (anos de estudo da esposa)
hispanic = 1 (a esposa é hispânica)
union = 0 (esposa não possui união estável)
exper = 18 (anos de experiência de trabalho da esposa)
kidlt6 = 1 (possui filhos menores de 6 anos)

obs: lembre-se de que a variável dependente "lwage" já está em logarítmo, portanto você não precisa aplicar o logaritmo nela para fazer as regressões, mas é necessário aplicar o antilog para obter o resultado da predição.

B – RESOLUÇÃO

1 Regressões Ridge, Lasso e ElasticNet

```
Rotina utilizada para realizar as regressões Ridge, Lasso e ElasticNet
# Carregando os pacotes necessários
library(plyr)
library(readr)
library(dplyr)
library(caret)
```

```
library(ggplot2)
library(repr)
library(glmnet)

set.seed(123)

# Carregando base de dados
load('trabalhosalarios.RData')

# armazenando base de dados
dataset <- trabalhosalarios

# diminuindo a variancia de husage e age - as outras possuem zero
dataset['husage'] <- log(dataset['husage'])
dataset['age'] <- log(dataset['age'])

# criando índice para separar em base de teste e de treino
index <- sample(1:nrow(dataset), 0.8*nrow(dataset))

# criando base de treino
train <- dataset[index,]

# criando base de teste
test <- dataset[-index,]

# verificando dimensões das bases de treino e teste
dim(train)
dim(test)

# Vamos padronizar as variaveis
# Vamos criar um objeto com as variaveis para padronizar
# As variaveis binarias nao sao padronizadas
cols = c('husage', 'husearns', 'huseduc', 'hushrs', 'age', 'educ', 'exper')

# Padronizando a base de treinamento e teste
pre_proc_val <- preProcess(train[,cols], method = c("center", "scale"))
train[,cols] = predict(pre_proc_val, train[,cols])
test[,cols] = predict(pre_proc_val, test[,cols])

summary(train)
summary(test)
```

```
########################################
# REGRESSAO RIDGE                      #
########################################
# Vamos criar um objeto com as variaveis que usaremos no modelo
cols_reg = c('husage','husunion', 'husearns', 'huseduc', 'hushrs',
             'age', 'educ', 'husblck', 'hushisp', 'kidge6', 'black',
             'hispanic', 'union', 'kidlt6','exper','lwage')

# Vamos gerar variáveis dummies para organizar os datasets
# em objetos tipo matriz
# Estamos interessados em estimar o salário-hora da esposa em logaritmo
neperiano (lwage)
dummies <- dummyVars(lwage~husage+husunion+husearns+huseduc+hushrs+
                       age+educ+husblck+hushisp+
                       kidge6+black+hispanic+union+kidlt6+exper,
                     data = dataset[,cols_reg])
train_dummies = predict(dummies, newdata = train[,cols_reg])
test_dummies = predict(dummies, newdata = test[,cols_reg])
print(dim(train_dummies)); print(dim(test_dummies))

# Vamos guardar a matriz de dados de treinamento das
# variaveis explicativas para o modelo em um objeto
# chamado "x"
x = as.matrix(train_dummies)

# Vamos guardar o vetor de dados de treinamento da
# variavel dependente para o modelo em um objeto
# chamado "y_train"
y_train = train$lwage

# Vamos guardar a matriz de dados de teste das variaveis
# explicativas para o modelo em um objeto chamado
# "x_test"
x_test = as.matrix(test_dummies)

# Vamos guardar o vetor de dados de teste da variavel
# dependente para o modelo em um objeto chamado "y_test"
y_test = test$lwage

# Vamos calcular o valor otimo de lambda;
# alpha = "0", é para regressao Ridge
```

```
# Vamos testar os lambdas de 10^-3 até 10^2, a cada 0.1
lambdas <- 10^seq(2, -3, by = -.1)

# Calculando o lambda:
ridge_lamb <- cv.glmnet(x, y_train, alpha = 0, lambda = lambdas)

# Vamos ver qual o lambda otimo
best_lambda_ridge <- ridge_lamb$lambda.min
best_lambda_ridge

# Estimando o modelo Ridge
ridge_reg = glmnet(x, y_train, nlambda = 25, alpha = 0, family = 'gaussian',
                   lambda = best_lambda_ridge)

# Vamos ver o resultado (valores) da estimativa
# (coeficientes)
ridge_reg[["beta"]]

# Vamos calcular o R^2 dos valores verdadeiros e
# preditos conforme a seguinte funcao:
eval_results <- function(true, predicted, df) {
  SSE <- sum((predicted - true)^2)
  SST <- sum((true - mean(true))^2)
  R_square <- 1 - SSE / SST
  RMSE = sqrt(SSE/nrow(df))

  # As metricas de performace do modelo:
  data.frame(
    RMSE = RMSE,
    Rsquare = R_square
  )
}

# Predicao e avaliacao nos dados de treinamento:
predictions_train <- predict(ridge_reg, s = best_lambda_ridge,
                             newx = x)

# As metricas da base de treinamento sao:
eval_results(y_train, predictions_train, train)
#  RMSE      Rsquare
#1 0.4361332 0.306454
```

```
# Predicao e avaliacao nos dados de teste:
predictions_test <- predict(ridge_reg, s = best_lambda_ridge,
                            newx = x_test)

# As metricas da base de teste sao:
eval_results(y_test, predictions_test, test)
#  RMSE      Rsquare
#1 0.4503715 0.2346912

# Se compararmos as metricas de treinamento e teste
# percebemos que o R² é relativamente baixo em ambas, o que sugere
# que o modelo não está adequado para capturara variabilidade
# dos dados. Em resumo, o modelo não demonstra
# ter um bom poder explicativo.

##########################################
#  REGRESSAO LASSO                       #
##########################################
# Vamos atribuir alpha = 1 para implementar a regressao lasso
lasso_lamb <- cv.glmnet(x, y_train, alpha = 1, lambda = lambdas,
                        standardize = TRUE, nfolds = 5)

# Vamos guardar o lambda "otimo" em um objeto chamado
# best_lambda_lasso
best_lambda_lasso <- lasso_lamb$lambda.min
best_lambda_lasso

# Vamos estimar o modelo Lasso
lasso_model <- glmnet(x, y_train, alpha = 1, lambda = best_lambda_lasso,
                      standardize = TRUE)

# Vamos visualizar os coeficientes estimados
lasso_model[["beta"]]

# Vamos fazer as predicoes na base de treinamento e
# avaliar a regressao Lasso
predictions_train_lasso <- predict(lasso_model, s = best_lambda_lasso,
                                   newx = x)
# Vamos calcular o R^2 dos valores verdadeiros e preditos
# As metricas da base de treinamento sao:
eval_results(y_train, predictions_train_lasso, train)
```

```
#  RMSE     Rsquare
#1 0.436358 0.305739

# Vamos fazer as predicoes na base de teste
predictions_test_lasso <- predict(lasso_model, s = best_lambda_lasso,
                                  newx = x_test)

# As metricas da base de teste sao:
eval_results(y_test, predictions_test_lasso, test)
#   RMSE   Rsquare
#1  0.4503179 0.2348735

# Novamente, se compararmos as metricas de treinamento e teste
# percebemos que o R² é relativamente baixo em ambas, o que sugere
# que este modelo também não está adequado para capturara variabilidade
# dos dados. Em resumo, o modelo não demonstra
# ter um bom poder explicativo.

##########################################
#  REGRESSAO ELASTICNET                  #
##########################################
# Vamos configurar o treinamento do modelo por
# cross validation, com 10 folders, 5 repeticoes
# e busca aleatoria dos componentes das amostras
# de treinamento, o "verboseIter" é soh para
# mostrar o processamento.
train_cont <- trainControl(method = "repeatedcv", number = 10,
                           repeats = 5, search = "random",
                           verboseIter = TRUE)

# Vamos treinar o modelo
elastic_reg <- train(lwage~husage+husunion+husearns+huseduc+hushrs+
                       age+educ+husblck+hushisp+
                       kidge6+black+hispanic+union+kidlt6+exper,
                     data = train,
                     method = "glmnet",
                     tuneLength = 10,
                     trControl = train_cont)
# O melhor parametro alpha escolhido é:
elastic_reg$bestTune
```

```
# E os parametros sao:
elastic_reg[["finalModel"]][["beta"]]

# Vamos fazer as predicoes e avaliar a performance do modelo

# Vamos fazer as predicoes no modelo de treinamento:
predictions_train_elasticnet <- predict(elastic_reg, x)

# As metricas de performance na base de treinamento sao:
eval_results(y_train, predictions_train_elasticnet, train)
#   RMSE     Rsquare
# 1 0.437097 0.3033854

# Vamos fazer as predicoes na base de teste
predictions_test_elasticnet <- predict(elastic_reg, x_test)

# As metricas de performance na base de teste sao:
eval_results(y_test, predictions_test_elasticnet, test)
#  RMSE      Rsquare
#1 0.4508652 0.23301243

# O modelo com elasticnet também apresentou métricas de desempenho
# relativamente baixas, tanto para treino quanto para teste.
# Em resumo, o modelo não demonstra
# ter um bom poder explicativo.

##########################################
# Escolha do melhor modelo
# O modelo de Lasso parece ser a melhor escolha, pois apresenta o menor RMSE
# e o maior R² na base de teste, indicando uma melhor capacidade de previsão
# e explicação da variabilidade dos dados de teste em comparação aos outros
# modelos.

# No entanto, as diferenças são mínimas, e todos os modelos apresentam
# desempenho muito semelhante.

##########################################
# Preparando valores para as predições
# husage = 40 anos (idade do marido)
husage = (log(40)-pre_proc_val[["mean"]][["husage"]])/
  pre_proc_val[["std"]][["husage"]]
```

```
husunion = 0

# husearns = 600 (rendimento do marido em US$)
husearns = (600-pre_proc_val[["mean"]][["husearns"]])/
  pre_proc_val[["std"]][["husearns"]]

# huseduc = 13 (anos de estudo do marido)
huseduc = (13-pre_proc_val[["mean"]][["huseduc"]])/
  pre_proc_val[["std"]][["huseduc"]]

# husblck = 1 (o marido é preto)
husblck = 1

# hushisp = 0 (o marido nao é hispanico)
hushisp = 0

# hushrs = 40 (o marido trabalha 40 horas semanais)
hushrs = (40-pre_proc_val[["mean"]][["hushrs"]])/
  pre_proc_val[["std"]][["hushrs"]]

# kidge6 = 0 (nao tem filhos maiores de 6 anos)
kidge6 = 1

# age = 38 anos (idade da esposa)
age = (log(38)-pre_proc_val[["mean"]][["age"]])/
  pre_proc_val[["std"]][["age"]]

# black = 0 (esposa nao é preta)
black = 0

# educ = 13 (esposa possui 13 anos de estudo)
educ = (13-pre_proc_val[["mean"]][["educ"]])/
  pre_proc_val[["std"]][["educ"]]

# hispanic = 1 (esposa é hispanica)
hispanic = 1

# union = 0 (o casal nao possui uniao registrada)
union = 0

# exper = 18 (esposa possui 18 anos de experiência)
```

```
exper = (18-pre_proc_val[["mean"]][["exper"]])/
  pre_proc_val[["std"]][["exper"]]

# kidlt6 = 0 (nao possui filhos com menos de 6 anos)
kidlt6 = 1

# Vamos construir uma matriz de dados para a predicao
our_pred = as.matrix(data.frame(husage=husage,
                                husunion=husunion,
                                husearns=husearns,
                                huseduc=huseduc,
                                husblck=husblck,
                                hushisp=hushisp,
                                hushrs=hushrs,
                                kidge6=kidge6,
                                age=age,
                                black=black,
                                educ=educ,
                                hispanic=hispanic,
                                union=union,
                                exper=exper,
                                kidlt6=kidlt6))

##########################################
#  PREDIÇÃO RIDGE                        #
##########################################
# Fazendo a predicao:
predict_our_ridge <- predict(ridge_reg, s = best_lambda_ridge,
                             newx = our_pred)

# O resultado da predicao é:
predict_our_ridge

# O resultado é um valor padronizado, vamos convertê-lo
# para o valor nominal, consistente com o dataset original
lwage_pred_ridge=exp(predict_our_ridge)

# O resultado é:
lwage_pred_ridge

# Este é o valor predito do salário por hora (US$),
```

```
# segundo as caracteristicas que atribuimos

# O intervalo de confianca para o nosso exemplo é:
n <- nrow(train) # tamanho da amostra
m <- lwage_pred_ridge # valor medio predito
s <- sd(dataset$lwage) # desvio padrao
dam <- s/sqrt(n) # distribuicao da amostragem da média
CIlwr_ridge <- m + (qnorm(0.025))*dam # intervalo inferior
CIupr_ridge <- m - (qnorm(0.025))*dam # intervalo superior

# Os valores sao:
CIlwr_ridge
CIupr_ridge

# Entao, segundo as caracteristicas que atribuimos o
# salário-hora da esposa é em média US$6.27305 e pode
# variar entre US$6.2505 e US$6.295599

##########################################
#  PREDIÇÃO LASSO                        #
##########################################
# Fazendo a predição
predict_our_lasso <- predict(lasso_model, s = best_lambda_lasso,
                             newx = our_pred)

# O resultado da predicao é:
predict_our_lasso

# O resultado é um valor padronizado, vamos convertê-lo
# para o valor nominal, consistente com o dataset original
lwage_pred_lasso = exp(predict_our_lasso)

# O resultado é:
lwage_pred_lasso

# Vamos criar o intervalo de confianca para o nosso exemplo
n <- nrow(train)
m <- lwage_pred_lasso
s <- sd(dataset$lwage) # desvio padrao
dam <- s/sqrt(n)
CIlwr_lasso <- m + (qnorm(0.025))*dam
```

```
CIupr_lasso <- m - (qnorm(0.025)) *dam

# O intervalo de confianca é:
CIlwr_lasso
CIupr_lasso

# Entao, o salário medio é de US$6.253206 e pode variar
# entre US$6.230657 e US$6.275756

##########################################
#  PREDIÇÃO ELASTICNET                   #
##########################################
# Vamos fazer a predicao com base nos parametros que
# selecionamos
predict_our_elastic <- predict(elastic_reg,our_pred)
predict_our_elastic

# Novamente, o resultado é padronizado, nós temos que revertê-lo para o
# nivel dos valores originais do dataset, vamos fazer isso:
lwage_pred_elastic=exp(predict_our_elastic)
lwage_pred_elastic

# Entao o salário-hora medio da esposa predito com base
# nas caracteristicas informadas é US$7.8397

# Vamos criar o intervalo de confianca para o nosso exemplo
n <- nrow(train)
m <- lwage_pred_elastic
s <- sd(dataset$lwage) # desvio padrao
dam <- s/sqrt(n)
CIlwr_elastic <- m + (qnorm(0.025))*dam
CIupr_elastic <- m - (qnorm(0.025))*dam

# Os valores minimo e maximo sao:
CIlwr_elastic
CIupr_elastic

# Entao, o salário-hora medio da esposa é de US$7.8397
# e pode variar entre US$7.81715 e US$7.86225
```

2 Tabela com as estatísticas dos modelos (RMSE e R^2)

Tipo de Regressão	Treino		Teste	
	R^2	RMSE	R^2	RMSE
Ridge	0.306454	0.4361332	0.2346912	0.4503715
Lasso	0.305739	0.436358	0.2348735	0.4503179
ElasticNet	0.3033854	0.437097	0.23301243	0.4508652

Escolha do melhor modelo:

O modelo de Lasso parece ser a melhor escolha, pois apresenta o menor RMSE e o maior R^2 na base de teste, indicando uma melhor capacidade de previsão e explicação da variabilidade dos dados de teste em comparação aos outros modelos.

No entanto, as diferenças são mínimas, e todos os modelos apresentam desempenho muito semelhante.

3 Predições

Tipo de Regressão	Resultado	Resultado com antilog	Intervalo Inferior	Intervalo Superior
Ridge	1.836263	6.27305	6.2505	6.295599
Lasso	1.833094	6.253206	6.230657	6.275756
ElasticNet	2.059201	7.8397	7.81715	7.86225

APÊNDICE 6 – ARQUITETURA DE DADOS

A – ENUNCIADO

1 Construção de Características: Identificador automático de idioma

O problema consiste em criar um modelo de reconhecimento de padrões que dado um texto de entrada, o programa consegue classificar o texto e indicar a língua em que o texto foi escrito.

Parta do exemplo (notebook produzido no Colab) que foi disponibilidade e crie as funções para calcular as diferentes características para o problema da identificação da língua do texto de entrada.

Nessa atividade é para "construir características".

Meta: a acurácia deverá ser maior ou igual a 70%.

Essa tarefa pode ser feita no Colab (Google) ou no Jupiter, em que deverá exportar o notebook e imprimir o notebook para o formato PDF. Envie no UFPR Virtual os dois arquivos.

2 Melhore uma base de dados ruim

Escolha uma base de dados pública para problemas de classificação, disponível ou com origem na UCI Machine Learning.

Use o mínimo de intervenção para rodar a SVM e obtenha a matriz de confusão dessa base.

O trabalho começa aqui, escolha as diferentes tarefas discutidas ao longo da disciplina, para melhorar essa base de dados, até que consiga efetivamente melhorar o resultado.

Considerando a acurácia para bases de dados balanceadas ou quase balanceadas, se o percentual da acurácia original estiver em até 85%, a meta será obter 5%. Para bases com mais de 90% de acurácia, a meta será obter a melhora em pelo menos 2 pontos percentuais (92% ou mais).

Nessa atividade deverá ser entregue o script aplicado (o notebook e o PDF correspondente).

B – RESOLUÇÃO

Códigos Python utilizados no ambiente Google Colab

1 Construção de Características: Identificador automático de idioma

```
import re
from collections import Counter
from sklearn.model_selection import train_test_split
from sklearn.svm import SVC
from sklearn.metrics import classification_report
from sklearn.preprocessing import StandardScaler
from sklearn.decomposition import PCA
import numpy as np
from sklearn.impute import SimpleImputer
from sklearn.model_selection import RepeatedStratifiedKFold, cross_val_score

ingles = [
"Hello, how are you?",
"I love to read books.",
"The weather is nice today.",
"Where is the nearest restaurant?",
"What time is it?",
"I enjoy playing soccer.",
"Can you help me with this?",
"I'm going to the movies tonight.",
"This is a beautiful place.",
"I like listening to music.",
"Do you speak English?",
"What is your favorite color?",
"I'm learning to play the guitar.",
"Have a great day!",
"I need to buy some groceries.",
"Let's go for a walk.",
"How was your weekend?",
"I'm excited for the concert.",
"Could you pass me the salt, please?",
"I have a meeting at 2 PM.",
"I'm planning a vacation.",
"She sings beautifully.",
"The cat is sleeping.",
"I want to learn French.",
"I enjoy going to the beach.",
```

```
"Where can I find a taxi?",
"I'm sorry for the inconvenience.",
"I'm studying for my exams.",
"I like to cook dinner at home.",
"Do you have any recommendations for restaurants?",
]

espanhol = [
"Hola, ¿cómo estás?",
"Me encanta leer libros.",
"El clima está agradable hoy.",
"¿Dónde está el restaurante más cercano?",
"¿Qué hora es?",
"Voy al parque todos los días.",
"¿Puedes ayudarme con esto?",
"Me gustaría ir de vacaciones.",
"Este es mi libro favorito.",
"Me gusta bailar salsa.",
"¿Hablas español?",
"¿Cuál es tu comida favorita?",
"Estoy aprendiendo a tocar el piano.",
"¡Que tengas un buen día!",
"Necesito comprar algunas frutas.",
"Vamos a dar un paseo.",
"¿Cómo estuvo tu fin de semana?",
"Estoy emocionado por el concierto.",
"¿Me pasas la sal, por favor?",
"Tengo una reunión a las 2 PM.",
"Estoy planeando unas vacaciones.",
"Ella canta hermosamente.",
"El perro está jugando.",
"Quiero aprender italiano.",
"Disfruto ir a la playa.",
"¿Dónde puedo encontrar un taxi?",
"Lamento las molestias.",
"Estoy estudiando para mis exámenes.",
"Me gusta cocinar la cena en casa.",
"¿Tienes alguna recomendación de restaurantes?",
]
```

```
portugues = [
"Estou indo para o trabalho agora.",
"Adoro passar tempo com minha família.",
"Preciso comprar leite e pão.",
"Vamos ao cinema no sábado.",
"Gosto de praticar esportes ao ar livre.",
"O trânsito está terrível hoje.",
"A comida estava deliciosa!",
"Você já visitou o Rio de Janeiro?",
"Tenho uma reunião importante amanhã.",
"A festa começa às 20h.",
"Estou cansado depois de um longo dia de trabalho.",
"Vamos fazer um churrasco no final de semana.",
"O livro que estou lendo é muito interessante.",
"Estou aprendendo a cozinhar pratos novos.",
"Preciso fazer exercícios físicos regularmente.",
"Vou viajar para o exterior nas férias.",
"Você gosta de dançar?",
"Hoje é meu aniversário!",
"Gosto de ouvir música clássica.",
"Estou estudando para o vestibular.",
"Meu time de futebol favorito ganhou o jogo.",
"Quero aprender a tocar violão.",
"Vamos fazer uma viagem de carro.",
"O parque fica cheio aos finais de semana.",
"O filme que assisti ontem foi ótimo.",
"Preciso resolver esse problema o mais rápido possível.",
"Adoro explorar novos lugares.",
"Vou visitar meus avós no domingo.",
"Estou ansioso para as férias de verão.",
"Gosto de fazer caminhadas na natureza.",
"O restaurante tem uma vista incrível.",
"Vamos sair para jantar no sábado.",
]
import random

pre_padroes = []

for frase in ingles:
  pre_padroes.append( [frase, 'inglês'])
```

```
for frase in espanhol:
  pre_padroes.append( [frase, 'espanhol'])

for frase in portugues:
  pre_padroes.append( [frase, 'português'])

random.shuffle(pre_padroes)

import pandas as pd
dados = pd.DataFrame(pre_padroes)
dados
```

	0	1
0	Voy al parque todos los días.	espanhol
1	Me gusta cocinar la cena en casa.	espanhol
2	Vamos ao cinema no sábado.	português
3	Vamos a dar un paseo.	espanhol
4	I'm excited for the concert.	inglês
...	...	...
87	What time is it?	inglês
88	I'm sorry for the inconvenience.	inglês
89	Tengo una reunión a las 2 PM.	espanhol
90	I like to cook dinner at home.	inglês
91	Estou cansado depois de um longo dia de trabalho.	português

92 rows × 2 columns

```
def tamanhoMedioFrases(texto):
    palavras = re.split("\s", texto)
    tamanhos = [len(s) for s in palavras if len(s) > 0]
    return sum(tamanhos) / len(tamanhos)

def tamanho_frase(frase):
    return len(frase.split())

def encontros_pt(frase):
  encontros = ['ss','rr', 'ão']
  if any(char in frase for char in encontros):
    return 1
  else:
    return 0

def art_prep_espanhol(frase):
artigos_pre_espanhois = ['el', 'la', 'los', 'las', 'un', 'una', 'unos',
'unas', 'lo', 'bajo', 'en', 'hacia', 'hasta', 'según', 'sin', 'vía']
palavras = re.split('\s', frase.lower())

if any(artigo in palavras for artigo in artigos_pre_espanhois):
    return 1
```

```
  else:
    return 0

def caracter_espanhol(frase):
  caracteres_espanhois = ['Ñ','ñ', '¡', '¿']
  if any(char in frase for char in caracteres_espanhois):
    return 1
  else:
    return 0

def frequencia_letras(frase):
    letras = re.findall(r'\w', frase.lower())
    contador = Counter(letras)
    total_letras = sum(contador.values())
    frequencia = {f'freq_{letra}': count / total_letras for letra, count in
contador.items()}
    return frequencia

def ocorrencia_simbolos_especiais(frase):
    especiais = re.findall(r'[ñç]', frase.lower())
    contador = Counter(especiais)
    frequencia = {f'simbolo_{s}': count for s, count in contador.items()}
    return frequencia

def sufixos_palavras(frase, tamanho=3):
    palavras = frase.split()
    sufixos = [palavra[-tamanho:] for palavra in palavras if len(palavra) >=
tamanho]
    contador = Counter(sufixos)
    frequencia = {f'sufixo_{s}': count for s, count in contador.items()}
    return frequencia

def encontros_es(frase):
  encontros = ['ll','ch', 'qu']
  if any(char in frase for char in encontros):
    return 1
  else:
    return 0

def encontros_ing(frase):
  encontros = ['ll','mm', 'aa','ee', 'ii', 'oo', 'uu', 'ff']
```

```
  if any(char in frase for char in encontros):
    return 1
  else:
    return 0

def extraiCaracteristicas(frase):
    texto = frase[0]
    pattern_regex = re.compile('[^\w+]', re.UNICODE)
    texto = re.sub(pattern_regex, ' ', texto)

    caracteristica1 = tamanhoMedioFrases(texto)
    caracteristica2 = tamanho_frase(texto)
    caracteristica4 = ocorrencia_simbolos_especiais(texto)
    caracteristica6 = sufixos_palavras(texto)
    caracteristica8 = art_prep_espanhol(texto)
    caracteristica9 = encontros_pt(texto)
    caracteristica10 = encontros_es(texto)
    caracteristica11 = encontros_ing(texto)
    caracteristica12 = caracter_espanhol(texto)

    padrao = {
        'tamanhoMedioFrases': caracteristica1,
        'tamanho_frase': caracteristica2,
        **caracteristica4,
        **caracteristica6,
        'pre-espanhol':caracteristica8,
        'en-pt':caracteristica9,
        'en-es':caracteristica10,
        'en-en':caracteristica11,
        'es':caracteristica12,
        'classe': frase[1]
    }
    return padrao

def geraPadroes(frases):
    padroes = []
    for frase in frases:
        padrao = extraiCaracteristicas(frase)
        padroes.append(padrao)
    return padroes
```

```
padroes = geraPadroes(pre_padroes)
dados = pd.DataFrame(padroes)

colunas_numericas = dados.select_dtypes(include=[np.number]).columns
imputer = SimpleImputer(strategy='mean')
dados[colunas_numericas] = imputer.fit_transform(dados[colunas_numericas])

scaler = StandardScaler()
dados[colunas_numericas] = scaler.fit_transform(dados[colunas_numericas])
```

	tamanhoMedioFrases	tamanho_frase	vogais	consoantes	sufixo_Voy	sufixo_que	sufixo_dos	sufixo_los	sufixo_ías	pre-espanhol	...
0	-0.646029	0.461833	-0.327281	0.327281	0.0	0.0	0.0	0.0	0.0	2.265686	...
1	-0.748238	1.194395	0.172681	-0.172681	0.0	0.0	0.0	0.0	0.0	2.265686	...
2	-0.331227	-0.270729	1.336284	-1.336284	0.0	0.0	0.0	0.0	0.0	-0.441367	...
3	-1.189780	-0.270729	0.891377	-0.891377	0.0	0.0	0.0	0.0	0.0	2.265686	...
4	-0.789122	0.461833	-1.656726	1.656726	0.0	0.0	0.0	0.0	0.0	-0.441367	...
...	...	...	...	...	...	...	...	...	...	...	...
87	-1.361490	-1.003292	-0.665797	0.665797	0.0	0.0	0.0	0.0	0.0	-0.441367	...
88	-0.216753	0.461833	-1.264710	1.264710	0.0	0.0	0.0	0.0	0.0	-0.441367	...
89	-1.238840	1.194395	0.042009	-0.042009	0.0	0.0	0.0	0.0	0.0	2.265686	...
90	-1.116189	1.194395	0.485158	-0.485158	0.0	0.0	0.0	0.0	0.0	-0.441367	...
91	-0.121358	2.659519	0.424225	-0.424225	0.0	0.0	0.0	0.0	0.0	-0.441367	...

92 rows × 228 columns

```
dados = dados.drop_duplicates()
dados = dados.dropna()

X = dados.drop(columns=['classe'])
y = dados['classe']

class_map = {'inglês': 0, 'espanhol': 1, 'português': 2}
y_encoded = y.map(class_map)

scaler = StandardScaler()
X_scaled = scaler.fit_transform(X)
pca = PCA(n_components=0.95)
X_pca = pca.fit_transform(X_scaled)

X_train, X_test, y_train, y_test = train_test_split(X_pca, y_encoded,
test_size=0.2, random_state=42)
modelo = SVC()
modelo.fit(X_train, y_train)

cv = RepeatedStratifiedKFold(n_splits=10, n_repeats=3, random_state=1)
```

```
scores = cross_val_score(modelo, X_train, y_train, scoring='accuracy', cv=cv,
n_jobs=-1)
acuracia_treinamento = modelo.score(X_train, y_train)
print("Acurácia no treino: {:.2f}%".format(acuracia_treinamento * 100))
acuracia_teste = modelo.score(X_test, y_test)
print("Acurácia no teste: {:.2f}%".format(acuracia_teste * 100))

y_pred = modelo.predict(X_test)
print(classification_report(y_test, y_pred))

Acurácia no treino: 74.63%
Acurácia no teste: 70.59%
              precision    recall  f1-score   support

           0       0.60      1.00      0.75         3
           1       0.67      0.40      0.50         5
           2       0.78      0.78      0.78         9

    accuracy                           0.71        17
   macro avg       0.68      0.73      0.68        17
weighted avg       0.71      0.71      0.69        17
```

Resultado dos testes após adição de novas características:

Acurácia	
No treino	74,63%
No teste	70,59%

Idioma	Precision	Recall	F1-Score	Support
Inglês (0)	0.60	1.00	0.75	3
Espanhol (1)	0.67	0.40	0.50	5
Português (2)	0.78	0.78	0.78	9
accuracy			0.71	17
macro avg	0.68	0.73	0.68	17
weigthed avg	0.71	0.71	0.69	17

2 Melhorar uma base de dados ruim

Base de referência: UCI-Predict students dropout and academic success

- Técnicas aplicadas
- Normalização com StandardScaler
- Seleção de atributos por PCA
- Correção de prevalência por repetição/remoção de exemplos da base

```
# Instalando pacotes necessários
!pip install pandas
!pip install seaborn
!pip install scikit-learn
!pip install numpy
!pip install matplotlib
!pip install ucimlrepo

# Bibliotecas necessárias
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import seaborn as sns
from sklearn.preprocessing import StandardScaler
from sklearn.decomposition import PCA
from sklearn.preprocessing import LabelEncoder
from sklearn.model_selection import train_test_split
from sklearn import svm
from sklearn.metrics import confusion_matrix
from sklearn.metrics import classification_report
from sklearn.utils import resample
from sklearn.utils import shuffle
from ucimlrepo import fetch_ucirepo

# Carregando base de dados
predict_students_dropout_and_academic_success = fetch_ucirepo(id=697)

X = predict_students_dropout_and_academic_success.data.features
y = predict_students_dropout_and_academic_success.data.targets

# Salvando as colunas
columns = X.columns
columns

# Verificando informações sobre o dataset
# metadata
print(predict_students_dropout_and_academic_success.metadata)

# Variable information
print(predict_students_dropout_and_academic_success.variables)
```

```
# Executando o SVM com o mínimo de intervenção
X_original = X.copy()
y_original = y.copy()

X_original_train, X_original_test, y_original_train, y_original_test =
            train_test_split(X_original, y_original, test_size=0.25,
             stratify=y_original,random_state=10)

treinador = svm.SVC()

modelo_orig = treinador.fit(X_original_train, y_original_train)

# Treinamento
y_original_pred = modelo_orig.predict(X_original_train)
cm_orig_train = confusion_matrix(y_original_train, y_original_pred)
print('Matriz de confusão - com os dados ORIGINAIS usados no TREINAMENTO')
print(cm_orig_train)
print(classification_report(y_original_train, y_original_pred))

# Teste
print('Matriz de confusão - com os dados ORIGINAIS usados para TESTES')
y2_original_pred = modelo_orig.predict(X_original_test)
cm_orig_test = confusion_matrix(y_original_test, y2_original_pred)
print(cm_orig_test)
print(classification_report(y_original_test, y2_original_pred))

# Aplicando tarefas de pré processamento
# Verificando se o dataset contém valores ausentes
X.isna().sum()
Marital Status                                  0
Application mode                                0
Application order                               0
Course                                          0
Daytime/evening attendance                      0
Previous qualification                          0
Previous qualification (grade)                  0
Nacionality                                     0
Mother's qualification                          0
Father's qualification                          0
Mother's occupation                             0
Father's occupation                             0
```

```
Admission grade                                 0
Displaced                                       0
Educational special needs                       0
Debtor                                          0
Tuition fees up to date                         0
Gender                                          0
Scholarship holder                              0
Age at enrollment                               0
International                                   0
Curricular units 1st sem (credited)             0
Curricular units 1st sem (enrolled)             0
Curricular units 1st sem (evaluations)          0
Curricular units 1st sem (approved)             0
Curricular units 1st sem (grade)                0
Curricular units 1st sem (without evaluations)  0
Curricular units 2nd sem (credited)             0
Curricular units 2nd sem (enrolled)             0
Curricular units 2nd sem (evaluations)          0
Curricular units 2nd sem (approved)             0
Curricular units 2nd sem (grade)                0
Curricular units 2nd sem (without evaluations)  0
Unemployment rate                               0
Inflation rate                                  0
GDP                                             0
dtype: int64

# Verificando tipos das variáveis
X.dtypes
Marital Status                                    int64
Application mode                                  int64
Application order                                 int64
Course                                            int64
Daytime/evening attendance                        int64
Previous qualification                            int64
Previous qualification (grade)                  float64
Nacionality                                       int64
Mother's qualification                            int64
Father's qualification                            int64
Mother's occupation                               int64
Father's occupation                               int64
Admission grade                                 float64
```

```
Displaced                                          int64
Educational special needs                          int64
Debtor                                             int64
Tuition fees up to date                            int64
Gender                                             int64
Scholarship holder                                 int64
Age at enrollment                                  int64
International                                      int64
Curricular units 1st sem (credited)                int64
Curricular units 1st sem (enrolled)                int64
Curricular units 1st sem (evaluations)             int64
Curricular units 1st sem (approved)                int64
Curricular units 1st sem (grade)                 float64
Curricular units 1st sem (without evaluations)     int64
Curricular units 2nd sem (credited)                int64
Curricular units 2nd sem (enrolled)                int64
Curricular units 2nd sem (evaluations)             int64
Curricular units 2nd sem (approved)                int64
Curricular units 2nd sem (grade)                 float64
Curricular units 2nd sem (without evaluations)     int64
Unemployment rate                                float64
Inflation rate                                   float64
GDP                                              float64
dtype: object
```

```
# Verificando valores das variáveis independentes
X.head()
```

	Marital Status	Application mode	Application order	Course	Daytime/evening attendance	Previous qualification	Previous qualification (grade)	Nacionality	Mother's qualification	Father's qualification	...
0	1	17	5	171	1	1	122.0	1	19	12	...
1	1	15	1	9254	1	1	160.0	1	1	3	...
2	1	1	5	9070	1	1	122.0	1	37	37	...
3	1	17	2	9773	1	1	122.0	1	38	37	...
4	2	39	1	8014	0	1	100.0	1	37	38	...

5 rows × 36 columns

```
# Aplicando NORMALIZAÇÃO nas variáveis independentes, que não são booleanas,
# para ajustar a escala dos valores
bool_columns = ['International','Displaced','Educational special needs','Debtor','Tuition fees up to date','Gender','Scholarship holder','Daytime/evening attendance']

non_bool_columns = X.columns.difference(bool_columns)
```

```
scaler = StandardScaler()
X_scaled = X.copy()
X_scaled[non_bool_columns] =
scaler.fit_transform(X_scaled[non_bool_columns])
X_scaled
```

	Marital Status	Application mode	Application order	Course	Daytime/evening attendance	Previous qualification	Previous qualification (grade)	Nacionality	Mother's qualification	Father's qualification	...
0	-0.294829	-0.095470	2.490896	-4.209520	1	-0.35023	-0.804841	-0.126298	-0.036018	-0.669778	...
1	-0.294829	-0.209869	-0.554068	0.192580	1	-0.35023	2.076819	-0.126298	-1.189759	-1.256427	...
2	-0.294829	-1.010660	2.490896	0.103404	1	-0.35023	-0.804841	-0.126298	1.117723	0.959802	...
3	-0.294829	-0.095470	0.207173	0.444115	1	-0.35023	-0.804841	-0.126298	1.181819	0.959802	...
4	1.356212	1.162916	-0.554068	-0.408389	0	-0.35023	-2.473171	-0.126298	1.117723	1.024985	...
...	...	...	...	...	...	...	...	...	...	...	...
4419	-0.294829	-1.010660	3.252137	0.444115	1	-0.35023	-0.577342	-0.126298	-1.189759	-1.386793	...
4420	-0.294829	-1.010660	0.207173	0.444115	1	-0.35023	-0.956508	14.916228	-1.189759	-1.386793	...
4421	-0.294829	-1.010660	-0.554068	0.311805	1	-0.35023	1.621820	-0.126298	1.117723	0.959802	...
4422	-0.294829	-1.010660	-0.554068	0.140722	1	-0.35023	3.593483	-0.126298	1.117723	0.959802	...
4423	-0.294829	-0.495866	-0.554068	0.444115	1	-0.35023	1.470154	2.911135	1.181819	0.959802	...

4424 rows × 36 columns

```
# Verificando relação das variáveis
plt.figure(figsize=(40,20))
sns.heatmap(X_scaled.corr("spearman"), annot = True, cmap="coolwarm")
plt.title("Mapa de Correlação das Variáveis\n", fontsize = 15)
plt.show()
```

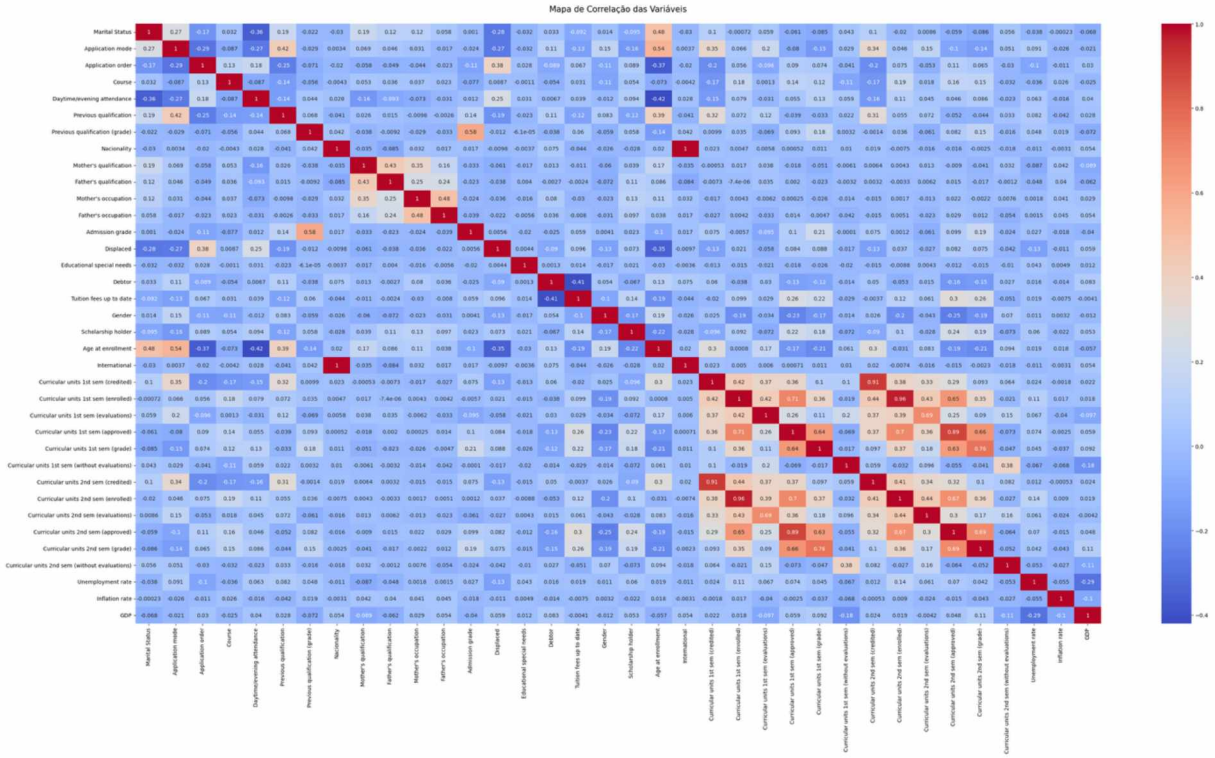


```
# Para tratar correlação e evitar possíveis problemas com multicolinearidade,
será aplicado PCA para SELEÇÃO dos atributos relavantes para passar ao modelo
```

```
pca = PCA(n_components=0.95)

# Aplicar o PCA aos dados
X_pca = pca.fit_transform(X_scaled)

# Criar um DataFrame com os componentes principais
columns = [f"PC{i+1}" for i in range(X_pca.shape[1])]
X_pca_df = pd.DataFrame(data=X_pca, columns=columns)

# Visualizar o DataFrame resultante
print(X_pca_df.head())
```

```
        PC1       PC2       PC3       PC4       PC5       PC6       PC7  \
0 -6.059586  0.201811 -1.005916  0.527048  1.763376 -2.949801  0.746578
1 -0.004017 -1.850271 -1.397830  1.924995 -0.047048  1.030895 -0.405920
2 -3.692111  0.297576  0.487145 -1.254448  0.679738 -2.220401  1.349643
3  0.366752 -0.613418  0.590129 -1.464175 -0.958946  0.078389  0.575616
4  0.296790  2.192877  0.765009 -0.598463 -2.325151  0.019984 -0.574183

        PC8       PC9      PC10  ...      PC13      PC14      PC15      PC16  \
0 -0.642022 -0.525059 -0.681361  ...  2.826824  0.969217  0.271315 -1.081445
1 -0.139694  0.169857 -0.431433  ... -1.017924 -0.386330  0.156920 -0.483792
2 -0.310848 -0.460915  0.456740  ...  0.003908 -1.091741  0.526780  0.179304
3 -0.184205 -0.741737 -1.400116  ... -0.299870  0.688548 -1.352081  0.118306
4 -0.579538  0.314171 -1.924611  ...  0.665829 -0.513619  0.080508 -1.205310

       PC17      PC18      PC19      PC20      PC21      PC22
0  0.168302  0.077148  0.519182 -0.234177  0.376751  0.294855
1 -0.258657 -0.514296  0.093626  0.316925  0.384840  0.189487
2  0.544726  0.592807  0.113959 -0.167895  0.352222  0.559909
3  0.150519 -0.117216 -0.459142 -0.443121 -0.165409 -0.095460
4  0.542704  2.074307  0.488774 -0.450120 -0.493568 -0.537161

[5 rows x 22 columns]
```

```
# Verificando variável dependente
y
```

	Target
0	Dropout
1	Graduate
2	Dropout
3	Graduate
4	Graduate
...	...
4419	Graduate
4420	Dropout
4421	Dropout
4422	Graduate
4423	Graduate

4424 rows × 1 columns

```
# Verificando distribuição das classes
y.value_counts()
Target
Graduate    2209
Dropout     1421
Enrolled     794
Name: count, dtype: int64

# CORREÇÃO DE PREVALÊNCIA
df = pd.concat([X_pca_df, y], axis=1)
df

# separando num df os dados de classe dropout, visto que irá manter a
quantidade
df_dropout = df[df['Target'] == 'Dropout']

# Separar os exemplos por classe onde será realizado correção de prevalência
# por replicação ou remoção
df_majority = df[df['Target'] == 'Graduate']
df_minority = df[df['Target'] == 'Enrolled']

# Definir o número desejado de exemplos para cada classe
desired_majority = 1400
desired_minority = 1200

# Realizar oversampling da classe minoritária ("Enrolled")
df_minority_oversampled = resample(df_minority,
                                   replace=True,
                                   n_samples=desired_minority,
                                   random_state=42)

# Realizar undersampling da classe majoritária ("Graduate")
df_majority_undersampled = resample(df_majority, replace=False,
                                    n_samples=desired_majority,
                                    random_state=42)

# Concatenar os DataFrames resultantes
X_balanced = pd.concat([df_majority_undersampled, df_minority_oversampled,
df_dropout])
```

```
# Embaralhar os dados
X_balanced = shuffle(X_balanced, random_state=42)

# Verificando dataframe final
X_balanced
```

	PC1	PC2	PC3	PC4	PC5	PC6	PC7	PC8	PC9	PC10	...
2268	0.434660	-0.084611	-0.945212	-0.559635	0.263854	0.670325	-2.511835	1.245759	-0.305851	-0.478124	...
1574	3.262675	3.799930	1.424455	-0.839713	-2.338506	-1.415100	0.281745	-2.347108	2.746128	-0.074747	...
476	-3.004276	-0.495796	0.272254	-0.711499	0.403599	-1.000193	-0.393799	-0.048836	-0.113517	-0.327428	...
3194	3.560689	1.111712	-0.224337	-0.200857	-0.005954	-0.719750	-1.260658	-0.375005	-0.152746	-0.144496	...
4422	-0.646688	-1.340220	-0.763030	1.998633	-1.484810	1.435375	3.113076	-0.456264	-0.299290	-0.968419	...
...	...	...	...	...	...	...	...	...	...	...	...
887	2.241349	2.782250	0.690181	-1.794337	-1.165949	-0.906929	-0.301800	-0.251182	-0.132333	-1.643701	...
632	1.167400	-1.988125	-0.499177	0.657878	-0.157527	0.482545	-0.421302	0.108697	-0.088488	-1.001690	...
3923	2.708243	2.882642	-0.140234	0.949814	-2.663997	0.284657	0.829696	-0.897254	1.594813	-1.445662	...
2931	-0.822146	2.385455	-1.769901	-4.216231	6.901834	6.401302	2.013309	-2.926140	0.296974	0.471835	...
1882	-3.343567	1.149101	0.426404	-0.423062	0.606158	-1.659483	0.182885	-0.955559	-0.329553	0.720788	...

4021 rows × 23 columns

```
# Separar novamente entre X e y para aplicar no modelo
X_trated = X_balanced.drop(columns='Target', axis=1)
y_treated = X_balanced['Target']

# Com os dados tratados
X_train, X_test, y_train, y_test = train_test_split(X_trated, y_treated,
test_size=0.25,

stratify=y_treated,random_state=10)

# Treinando e testando o modelo
treinador = svm.SVC()  #algoritmo escolhido

modelo = treinador.fit(X_train, y_train)

# Predição com os mesmos dados usados para treinar
y_pred = modelo.predict(X_train)
cm_train = confusion_matrix(y_train, y_pred)
print('Matriz de confusão - com os dados TRATADOS usados no TREINAMENTO')
print(cm_train)
print(classification_report(y_train, y_pred))
```

```
# Predição com os mesmos dados usados para testar
print('Matriz de confusão - com os dados TRATADOS usados para TESTES')
y2_pred = modelo.predict(X_test)
cm_test = confusion_matrix(y_test, y2_pred)
print(cm_test)
print(classification_report(y_test, y2_pred))
```

```
Matriz de confusão - com os dados TRATADOS usados no TREINAMENTO
[[747 214 104]
 [ 81 663 156]
 [ 33 120 897]]
              precision    recall  f1-score   support

     Dropout       0.87      0.70      0.78      1065
    Enrolled       0.66      0.74      0.70       900
    Graduate       0.78      0.85      0.81      1050

    accuracy                           0.77      3015
   macro avg       0.77      0.76      0.76      3015
weighted avg       0.77      0.77      0.77      3015

Matriz de confusão - com os dados TRATADOS usados para TESTES
[[226  85  45]
 [ 37 200  63]
 [ 14  57 279]]
              precision    recall  f1-score   support

     Dropout       0.82      0.63      0.71       356
    Enrolled       0.58      0.67      0.62       300
    Graduate       0.72      0.80      0.76       350

    accuracy                           0.70      1006
   macro avg       0.71      0.70      0.70      1006
weighted avg       0.71      0.70      0.70      1006
```

Resultado dos testes:

a) Matriz de confusão obtida após treinar e testar modelo SVM com o mínimo de intervenção:

Acurácia no treino: 50%

Classe	Precision	recall	F1-score	Support
Dropout	0.0	0.0	0.0	1066
Enrolled	0.0	0.0	0.0	595
Graduate	0.50	1.0	0.67	1657
Accuracy			0.50	3318
macro avg	0.17	0.33	0.22	3318
weighted avg	0.25	0.50	0.33	3318

Acurácia no teste: 50%

Classe	Precision	recall	F1-score	Support
Dropout	0.0	0.0	0.0	355
Enrolled	0.0	0.0	0.0	199
Graduate	0.50	1.0	0.67	552
Accuracy			0.50	1106
macro avg	0.17	0.33	0.22	1106
weighted avg	0.25	0.50	0.33	1106

b) Matriz de confusão obtida após treinar e testar modelo SVM com dados tratados:

Acurácia no treino: 77%

Classe	Precision	recall	F1-score	Support
Dropout	0.87	0.70	0.78	1065
Enrolled	0.66	0.74	0.70	900
Graduate	0.78	0.85	0.81	1050
Accuracy			0.77	3015
macro avg	0.77	0.76	0.76	3015
weighted avg	0.77	0.77	0.77	3015

Acurácia no teste: 70%

Classe	Precision	recall	F1-score	Support
Dropout	0.82	0.63	0.71	356
Enrolled	0.58	0.67	0.62	300
Graduate	0.72	0.80	0.76	350
Accuracy			0.70	1006
macro avg	0.71	0.70	0.70	1006
weighted avg	0.71	0.70	0.70	1006

APÊNDICE 7 – APRENDIZADO DE MÁQUINA

A – ENUNCIADO

Para cada uma das tarefas abaixo (Classificação, Regressão etc.) e cada base de dados (Veículo, Diabetes etc.), fazer os experimentos com todas as técnicas solicitadas (KNN, RNA etc.) e preencher os quadros com as estatísticas solicitadas, bem como os resultados pedidos em cada experimento.

B – RESOLUÇÃO

Classificação

Para o experimento de Classificação:

- Ordenar pela Acurácia (descendente), ou seja, a técnica de melhor acurácia ficará em primeiro na tabela.
- Após o quadro colocar:
  - Um resultado com 3 linhas com a predição de novos casos para a técnica/parâmetro de maior Acurácia (criar um arquivo com novos casos à sua escolha)
  - A lista de comandos emitidos no RStudio para conseguir os resultados obtidos

VEÍCULO

Técnica	Parâmetro	Acurácia	Matriz de Confusão
SVM – CV	C=50 Sigma=0.015	0.8529	Reference Prediction bus opel saab van bus 41 0 2 0 opel 0 32 8 0 saab 0 10 35 0 van 4 0 1 37

%Predição para novos casos:

Melhor acurácia foi obtida pelo SVM com Cross Validation:

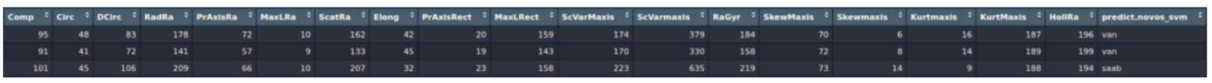

Comp	Circ	DCirc	RadRa	PrAxisRa	MaxLRa	ScatRa	Elong	PrAxisRect	MaxLRect	ScVarMaxis	ScVarmaxis	RaGyr	SkewMaxis	Skewmaxis	Kurtmaxis	KurtMaxis	HollRa	predict.novos_svm
95	48	83	178	72	10	162	42	20	159	174	379	184	70	6	16	187	196	van
91	41	72	141	57	9	133	45	19	143	170	330	158	72	8	14	189	199	van
101	45	106	209	66	10	207	32	23	158	223	635	219	73	14	9	188	194	saab

Script em R:

```
#######################################
#  CLASSIFICAÇÃO Veículo              #
#######################################
install.packages("e1071")
install.packages("caret")
install.packages("Metrics")
install.packages("mice")
```

```
install.packages("kernlab")
library(mice)
library("caret")
library(kernlab)

# Veículos
# Ler arquivo
setwd("~/Documentos/IBM/pós/IAA008-Aprendizado-de-
Maquina/trabalho/classificacao-veiculos")
dados <- read.csv("6 - Veiculos - Dados.csv")

# Remover atributo desnecessário
dados$a <- NULL

# Separação entre base de treino e teste que serão utilizadas em todos
os modelos
set.seed(202401)

randomIndexes <- sample(1:nrow(dados), 0.8 * nrow(dados))
treino <- dados[randomIndexes,]
## SVM
### C e sigma
set.seed(202401)
tuneGrid_svm = expand.grid(C=c(1, 2, 10, 50, 100), sigma=c(.01, .015,
0.2))

### Treinar SVM com a base de Treino
# Com Hold-out
svm <- train(tipo~., data=treino, method="svmRadial",
tuneGrid=tuneGrid_svm)
svm

### Aplicar modelos treinados na base de Teste
predict.svm <- predict(svm, teste)
confusionMatrix(predict.svm, as.factor(teste$tipo))

#### Cross-validation SVM
ctrl_svm <- trainControl(method = "cv", number = 10)
set.seed(202401)

svm_cv <- train(tipo~., data=treino, method="svmRadial",
```

```
trControl=ctrl_svm, tuneGrid=tuneGrid_svm)
svm_cv

### Matriz de confusão
predict.svm_cv <- predict(svm_cv, teste)
confusionMatrix(predict.svm_cv, as.factor(teste$tipo))

## Resultado -> SVM com Cross Validation obteve melhor acurácia
novos_dados <- read.csv('6-Veiculos- Novos-Dados.csv')
novos_dados$a <- NULL
predict.novos_svm <- predict(svm_cv, novos_dados)
resultado <- cbind(novos_dados, predict.novos_svm)
View(resultado)
```

DIABETES

Técnica	Parâmetro	Acurácia	Matriz de Confusão
RF – Hold-out	mtry=2	0.8117	Reference Prediction neg pos neg 102 21 pos 8 23

Predição para novos casos:

O Random Forest com Hold-Out obteve o melhor desempenho, logo, os novos casos serão preditos com Random Forest com Hold-Out.

preg0nt	glucose	pressure	triceps	insulin	mass	pedigree	age	predict.novos_rf_h
5	133	74	35	0	33.6	627	56	pos
1	85	66	29	0	26.6	351	41	neg
9	175	63	0	0	23.3	672	34	pos

Script em R:

```
#######################################
#  CLASSIFICAÇÃO Diabetes             #
#######################################
install.packages("e1071")
install.packages("caret")
install.packages("Metrics")
install.packages("mice")
install.packages("kernlab")
library(mice)
library("caret")
library(kernlab)
```

```
set.seed(202401)

# Diabetes
setwd("~/Documentos/IBM/pós/IAA008-Aprendizado-de-
Maquina/trabalho/classificacao-diabetes")
dados <- read.csv("10 - Diabetes - Dados.csv")

# Remover variável desnecessária
dados$num <- NULL
set.seed(202401)
randomIndexes <- sample(1:nrow(dados), 0.8 * nrow(dados))
treino <- dados[randomIndexes,]
teste <- dados[-randomIndexes,]

## Random Forest
#### Mtry
set.seed(202401)
tuneGrid_rf = expand.grid(mtry=c(2, 5, 7, 9))

# Treinar com hold out
rf_h <- train(diabetes~., data=treino, method="rf",
tuneGrid=tuneGrid_rf)
rf_h

### Aplicar modelos treinados na base de Teste
predict.rf_h <- predict(rf_h, teste)
confusionMatrix(predict.rf_h, as.factor(teste$diabetes))

#### Treinar com cross-validation
set.seed(202401)
ctrl_rf <- trainControl(method = "cv", number = 10)
rf_cv <- train(diabetes~., data=treino, method="rf",
tuneGrid=tuneGrid_rf, trControl=ctrl_rf)
rf_cv

### Aplicar modelos treinados na base de Teste
predict.rf_cv <- predict(rf_cv, teste)
confusionMatrix(predict.rf_cv, as.factor(teste$diabetes))

## Resultado -> RF com Hold out obteve a melhor acurácia
novos_dados <- read.csv('10-Diabetes-Novos-Dados.csv')
```

```
novos_dados$num <- NULL
novos_dados$diabetes <- NULL
predict.novos_rf_h <- predict(rf_h, novos_dados)
resultado <- cbind(novos_dados, predict.novos_rf_h)
View(resultado)
```

Regressão

Para o experimento de Regressão:

• Ordenar por R2 descendente, ou seja, a técnica de melhor R2 ficará em primeiro na tabela.

• Após o quadro colocar:

  o Um resultado com 3 linhas com a predição de novos casos para a técnica/parâmetro de maior R2 (criar um arquivo com novos casos à sua escolha)

  o Gráfico de Resíduos para a técnica/parâmetro de maior R2

  o A lista de comandos emitidos no RStudio para conseguir os resultados obtidos

Técnica	Parâmetro	R2	Syx	Pearson	Rmse	MAE
SVM – CV	C=10 Sigma=0.01	0.7939	0.0676	0.89133	0.0670	0.0463

Predição para novos casos:

O SVM com Cross Validation obteve o melhor R2.

GRE.Score	TOEFL.Score	University.Rating	SOP	LOR	CGPA	Research	predict.novos_svm_cv
337	118	4	4.5	4.5	9.35	1	0.9137410
323	105	4	4.0	4.5	8.87	1	0.8018283
315	105	3	3.0	3.5	8.00	1	0.6641024

Gráficos dos Ruídos:

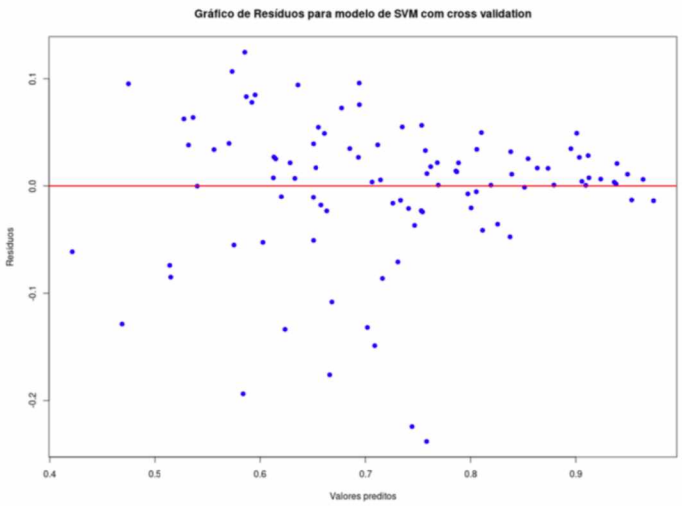

Script em R:

```
### Pacotes necessários:
install.packages("e1071")
install.packages("caret")
library("caret")
library(Metrics)

setwd("~/Documentos/IBM/pós/IAA008-Aprendizado-de-
Maquina/trabalho/regressao-admissao")
dados <- read.csv("9 - Admissao - Dados.csv", header=T)

# Remover variável desnecessária
dados$num <- NULL

### Cria arquivos de treino e teste usados em todos os modelos
set.seed(202401)
randomIndexes <- createDataPartition(dados$ChanceOfAdmit, p=0.80,
list = FALSE)
treino <- dados[randomIndexes,]
teste <- dados[-randomIndexes,]

# Cria funções necessárias para calculo das métricas
# Erro padrão da estimativa - Syx
standard_error <- function(obs, preds){
      size <- length(obs)
      sum_pos <- sum((obs - preds) ^ 2)
      result = sqrt((sum_pos / (size - 2)))
      return(result)}
mean_absolute_error <- function(obs, preds){
      size <- length(obs)
      sum_abs <- sum(abs(obs - preds))
      result <- sum_abs / size
      return(result)}
r2 <- function(predito, observado) {
      return(1 - (sum((predito-observado)^2) / sum((observado-
      mean(observado))^2)))}
pearson_coefficient <- function(obs, preds) {
      mean_obs <- mean(obs)
      mean_preds <- mean(preds)
      numerator <- sum((obs - mean_obs) * (preds - mean_preds))
      denominator <- sqrt(sum((obs - mean_obs)^2) * sum((preds -
```

```
      mean_preds)^2))
      result <- numerator / denominator
      return(result)}

## SVM
set.seed(202401)

#### Vários C e sigma
tuneGrid_svm = expand.grid(C=c(1, 2, 10, 50, 100),
      sigma=c(.01, .015,0.2))

### Treinar SVM com a base de Treino e Hold Out
svm_h <- train(ChanceOfAdmit~., data=treino, method="svmRadial",
tuneGrid=tuneGrid_svm)
svm_h

### Aplicar modelos treinados na base de Teste
predict.svm_h <- predict(svm_h, teste)

### Calcular métricas do svm com hold out
svm_h_rmse <- rmse(teste$ChanceOfAdmit, predict.svm_h)
svm_h_r2 <- r2(predict.svm_h,teste$ChanceOfAdmit)
svm_h_syx <- standard_error(teste$ChanceOfAdmit, predict.svm_h)
svm_h_mae <- mean_absolute_error(teste$ChanceOfAdmit,predict.svm_h)
svm_h_pearson <- pearson_coefficient(teste$ChanceOfAdmit,predict.svm_h)

## Treinar com cross validation
set.seed(202401)
ctrl_svm <- trainControl(method = "cv", number = 10)
svm_cv <- train(ChanceOfAdmit~., data=treino, method="svmRadial",
      trControl=ctrl_svm, tuneGrid=tuneGrid_svm)
svm_cv

### Aplicar modelos treinados na base de Teste
predict.svm_cv <- predict(svm_cv, teste)

### calcular métricas do svm com hold out
svm_cv_rmse <- rmse(teste$ChanceOfAdmit, predict.svm_cv)
svm_cv_r2 <- r2(predict.svm_cv,teste$ChanceOfAdmit)
svm_cv_syx <- standard_error(teste$ChanceOfAdmit, predict.svm_cv)
svm_cv_mae <- mean_absolute_error(teste$ChanceOfAdmit,predict.svm_cv)
```

```
svm_cv_pearson <- pearson_coefficient(teste$ChanceOfAdmit,
predict.svm_cv)

## Resultado -> SVM com cross validation obteve as melhores métricas
novos_dados <- read.csv('9-Admissao-Novos-Dados.csv')
novos_dados$num <- NULL
predict.novos_svm_cv <- predict(svm_cv, novos_dados)
resultado <- cbind(novos_dados, predict.novos_svm_cv)
View(resultado)
residuals_svm_cv <- teste$ChanceOfAdmit - predict.svm_cv

# Create the residual plot
plot(predict.svm_cv, residuals_svm_cv,
      main="Gráfico de Resíduos para modelo de SVM com cross
      validation", xlab="Valores preditos",
      ylab="Resíduos",
      pch=19, col="blue")
      abline(h=0, col="red", lwd=2)
```

BIOMASSA

Técnica	Parâmetro	R2	Syx	Pearson	Rmse	MAE
RNA – Hold-out	size=3 decay=0.4	0.8967	403.93	0.9860	397.14	133.92

Predição para novos casos:

O RNA com Hold-Out obteve o melhor R2.

dap	h	Me	predict.novos_rna_h
6.2	5.0	1.03	109.3212
7.2	5.0	1.04	120.0018
7.9	5.7	1.04	129.8521

Gráfico de Resíduos:

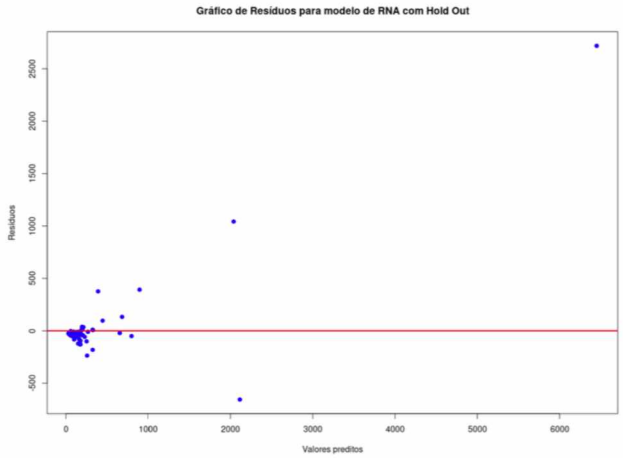

Script em R:

```
### Pacotes necessários:
install.packages("e1071")
install.packages("caret")
library("caret")
library(Metrics)
setwd("~/Documentos/IBM/pós/IAA008-Aprendizado-de-
Maquina/trabalho/regressao-biomassa")
dados <- read.csv("5 - Biomassa - Dados.csv", header=T)

### Cria arquivos de treino e teste
set.seed(202401)
randomIndexes <- createDataPartition(dados$biomassa, p=0.80, list =
      FALSE)
treino <- dados[randomIndexes,]
teste <- dados[-randomIndexes,]

# Cria funções necessárias para calculo das métricas
# Erro padrão da estimativa - Syx
standard_error <- function(obs, preds){
      size <- length(obs)
      sum_pos <- sum((obs - preds) ^ 2)
      result = sqrt((sum_pos / (size - 2)))
      return(result)}
mean_absolute_error <- function(obs, preds){
      size <- length(obs)
      sum_abs <- sum(abs(obs - preds))
      result <- sum_abs / size
      return(result)}
r2 <- function(predito, observado) {
      return(1 - (sum((predito-observado)^2) / sum((observado-
      mean(observado))^2)))}
pearson_coefficient <- function(obs, preds) {
      mean_obs <- mean(obs)
      mean_preds <- mean(preds)
      numerator <- sum((obs - mean_obs) * (preds - mean_preds))
      denominator <- sqrt(sum((obs - mean_obs)^2) * sum((preds -
            mean_preds)^2))
      result <- numerator / denominator
      return(result)}
```

```
# RNA
set.seed(202401)
tuneGrid_rna <- expand.grid(size = seq(from = 1, to = 3, by = 1), decay =
      seq(from = 0.1, to = 0.7, by = 0.3))

## Treino com hold out
rna_h <- train(biomassa~., data=treino, method="nnet", linout=T,
      trace=FALSE, tuneGrid=tuneGrid_rna)
rna_h
predict.rna_h <- predict(rna_h, teste)

### Calcular métricas do rna com hold out
rna_h_rmse <- rmse(teste$biomassa, predict.rna_h)
rna_h_r2 <-r2(predict.rna_h,teste$biomassa)
rna_h_syx <- standard_error(teste$biomassa, predict.rna_h)
rna_h_mae <- mean_absolute_error(teste$biomassa, predict.rna_h)
rna_h_pearson <- pearson_coefficient(teste$biomassa, predict.rna_h)

## Treino com cross validation CV
set.seed(202401)
control_rna <- trainControl(method = "cv", number = 10)
rna_cv <- train(biomassa~., data=treino, method="nnet",
      trainControl=control_rna, tuneGrid=tuneGrid_rna, linout=T,
      MaxNWts=10000, maxit=2000, trace=F)
rna_cv
predict.rna_cv <- predict(rna_cv, teste)

### Calcular métricas do rna com hold out
rna_cv_rmse <- rmse(teste$biomassa, predict.rna_cv)
rna_cv_r2 <- r2(predict.rna_cv,teste$biomassa)
rna_cv_syx <- standard_error(teste$biomassa, predict.rna_cv)
rna_cv_mae <- mean_absolute_error(teste$biomassa, predict.rna_cv)
rna_cv_pearson <- pearson_coefficient(teste$biomassa,
predict.rna_cv)

## Resultado -> RNA com Hold Out obteve as melhores métricas
novos_dados <- read.csv('5-Biomassa-Novos-Dados.csv')
novos_dados$biomassa <- NULL
predict.novos_rna_h <- predict(rna_h, novos_dados)
resultado <- cbind(novos_dados, predict.novos_rna_h)
View(resultado)
```

```
residuals_rna_h <- teste$biomassa - predict.rna_h

# Create the residual plot
plot(predict.rna_h, residuals_rna_h,
main="Gráfico de Resíduos para modelo de RNA com Hold Out",
xlab="Valores preditos",
ylab="Resíduos",
pch=19, col="blue")
abline(h=0, col="red", lwd=2)
```

Agrupamento

VEÍCULO

Lista de Clusters gerados:

• 10 primeiras linhas do arquivo com o cluster correspondente.

• Usar 10 clusters no experimento.

• Colocar a lista de comandos emitidos no RStudio para conseguir os resultados obtidos

Linhas do arquivo e clusters:

```
K-modes clustering with 10 clusters of sizes 63, 130, 125, 96, 67, 87, 48, 89, 82, 59

Cluster modes:
   Comp Circ DCirc RadRa PrAxisRa MaxLRa ScatRa Elong PrAxisRect MaxLRect ScVarMaxis ScVarmaxis RaGyr SkewMaxis Skewmaxis Kurtmaxis KurtMaxis HollRa Class
1    89   36    53   127       59      6    140    47         18      125        165        290   139        70         1        21       189    184  saab
2   104   51   104   197       60     10    213    31         24      162        223        669   218        72         0        11       188    199  saab
3   100   55   103   197       62     11    219    30         25      172        228        706   214        71         0         7       189    198  opel
4    85   43    68   120       65      7    150    46         19      145        169        341   171        85         4         8       179    182   bus
5    91   38    75   141       61      7    149    45         19      131        177        327   137        74         2        14       185    191  saab
6    85   45    70   130       56      7    151    45         19      146        170        333   186        81         4        11       181    183   bus
7    93   47    85   147       64      8    153    44         19      144        175        354   174        71         0         2       185    197   van
8    86   37    66   138       55      6    137    49         18      127        159        281   145        64         5        14       186    201   van
9    90   46    85   133       56     10    157    43         20      149        173        351   186        75         1        10       183    193   van
10   89   40    66   125       59      7    133    50         18      139        154        246   157        67         7         6       193    183   van
```

	Comp	Circ	DCirc	RadRa	PrAxisRa	MaxLRa	ScatRa	Elong	PrAxisRect	MaxLRect	ScVarMaxis	ScVarmaxis	RaGyr	SkewMaxis	Skewmaxis	Kurtmaxis	KurtMaxis	HollRa	Class	cluster.results$cluster
1	95	48	83	178	72	10	162	42	20	159	176	379	184	70	6	16	187	197	van	9
2	91	41	84	141	57	9	149	45	19	143	170	330	158	72	9	14	189	199	van	5
3	104	50	106	209	66	10	207	32	23	158	223	635	220	73	14	9	188	196	saab	2
4	93	41	82	159	63	9	144	46	19	143	160	309	127	63	6	10	199	207	van	7
5	85	44	70	205	103	52	149	45	19	144	241	325	188	127	9	11	180	183	bus	6
6	107	57	106	172	50	6	255	26	28	169	280	957	264	85	5	9	181	183	bus	6
7	97	43	73	173	65	6	153	42	19	143	176	361	172	66	13	1	200	204	bus	4
8	90	43	66	157	65	9	137	48	18	146	162	281	164	67	3	3	193	202	van	8
9	86	34	62	140	61	7	122	54	17	127	141	223	112	64	2	14	200	208	van	8
10	93	44	98	197	62	11	183	36	22	146	202	505	152	64	4	14	195	204	saab	3

Scripts em R:

```
### Pacotes necessários
install.packages("mlbench")
install.packages("mice")

## Para o k-modes
install.packages("klaR")
library(mlbench)
library(mice)
library(klaR)
```

```
### Leitura dos dados
#setwd("~/Documentos/IBM/pós/IAA008-Aprendizado-de-
Maquina/trabalho/agrupamento-veiculo")
dados <- read.csv("4 - Veiculos - Dados.csv")
View(dados)

# Remover variável desnecessária
dados$a <- NULL
set.seed(202401)
cluster.results <- kmodes(dados, 10, iter.max = 10, weighted = FALSE )
cluster.results$cluster
cluster.results
resultado <- cbind(dados, cluster.results$cluster)
resultado
```

Regras de Associação

MUSCULAÇÃO

- Regras geradas com uma configuração de Suporte e Confiança.
- Colocar a lista de comandos emitidos no RStudio para conseguir os resultados obtidos

Regras de confiança:

As 20 correspondências com maior confiança

	lhs		rhs	support	confidence	coverage	lift	count
[1]	{Afundo, Crucifixo}	=>	{Gemeos}	0.07692308	1	0.07692308	1.529412	2
[2]	{Crucifixo, Gemeos}	=>	{Afundo}	0.07692308	1	0.07692308	2.888889	2
[3]	{Afundo, Crucifixo}	=>	{LegPress}	0.07692308	1	0.07692308	1.238095	2
[4]	{Crucifixo, LegPress}	=>	{Afundo}	0.07692308	1	0.07692308	2.888889	2
[5]	{Crucifixo, Gemeos}	=>	{LegPress}	0.07692308	1	0.07692308	1.238095	2
[6]	{Crucifixo, LegPress}	=>	{Gemeos}	0.07692308	1	0.07692308	1.529412	2
[7]	{Adutor, Agachamento}	=>	{LegPress}	0.11538462	1	0.11538462	1.238095	3
[8]	{Adutor, LegPress}	=>	{Agachamento}	0.11538462	1	0.11538462	3.250000	3
[9]	{Esteira, Flexor}	=>	{Extensor}	0.07692308	1	0.07692308	2.000000	2
[10]	{Extensor, Flexor}	=>	{Esteira}	0.07692308	1	0.07692308	2.166667	2
[11]	{Esteira, Flexor}	=>	{Bicicleta}	0.07692308	1	0.07692308	1.857143	2
[12]	{Bicicleta, Flexor}	=>	{Esteira}	0.07692308	1	0.07692308	2.166667	2
[13]	{Esteira, Flexor}	=>	{LegPress}	0.07692308	1	0.07692308	1.238095	2
[14]	{Flexor, LegPress}	=>	{Esteira}	0.07692308	1	0.07692308	2.166667	2
[15]	{Extensor, Flexor}	=>	{Bicicleta}	0.07692308	1	0.07692308	1.857143	2
[16]	{Bicicleta, Flexor}	=>	{Extensor}	0.07692308	1	0.07692308	2.000000	2
[17]	{Extensor, Flexor}	=>	{LegPress}	0.07692308	1	0.07692308	1.238095	2
[18]	{Flexor, LegPress}	=>	{Extensor}	0.07692308	1	0.07692308	2.000000	2
[19]	{Bicicleta, Flexor}	=>	{LegPress}	0.07692308	1	0.07692308	1.238095	2
[20]	{Flexor, LegPress}	=>	{Bicicleta}	0.07692308	1	0.07692308	1.857143	2

Scripts em R:

```
### Instalação dos pacotes necessários
install.packages('arules', dep=T)
library(arules)
```

```
set.seed(202401)

# Ler arquivo
setwd("~/Documentos/IBM/pós/IAA008-Aprendizado-de-
Maquina/trabalho/associacao-musculacao")
dados <- read.transactions(file="2 - Musculacao -
      Dados.csv",format="basket",sep=";")
summary(dados)

# Ver frequencia dos itens
itemFrequencyPlot(dados, topN=10, type="absolute")

# Extrair regras
set.seed(202401)
rules <- apriori(dados, parameter = list(supp = 0.001, conf = 0.7,minlen=3))
summary(rules)

# Visualizar as 20 regras com maior confiança
inspect(sort(rules[1:20], by="confidence"))
```

APÊNDICE 8 – DEEP LEARNING

A – ENUNCIADO

1 Classificação de Imagens (CNN)

Implementar o exemplo de classificação de objetos usando a base de dados CIFAR10 e a arquitetura CNN vista no curso.

2 Detector de SPAM (RNN)

Implementar o detector de spam visto em sala, usando a base de dados SMS Spam e arquitetura de RNN vista no curso.

3 Gerador de Dígitos Fake (GAN)

Implementar o gerador de dígitos *fake* usando a base de dados MNIST e arquitetura GAN vista no curso.

4 Tradutor de Textos (Transformer)

Implementar o tradutor de texto do português para o inglês, usando a base de dados e a arquitetura Transformer vista no curso.

B – RESOLUÇÃO

1 Classificação de Imagens (CNN)

```
import tensorflow as tf
import numpy as np
import matplotlib.pyplot as plt
from tensorflow.keras.layers import Input, Conv2D, Dense, Flatten, Dropout,
      AveragePooling2D
from tensorflow.keras.models import Model
from mlxtend.plotting import plot_confusion_matrix
from sklearn.metrics import confusion_matrix

# Base
cifar10 = tf.keras.datasets.cifar10
(x_train, y_train), (x_test, y_test) = cifar10.load_data()
```

```
# Normalização dos dados
x_train, x_test = x_train / 255.0, x_test / 255.0
y_train, y_test = y_train.flatten(), y_test.flatten()

K = len(set(y_train))

i = Input(shape=x_train[0].shape)
x = Conv2D(32, (3, 3), strides=1, activation="relu")(i)
x = AveragePooling2D(pool_size=(2,2),strides=2, padding="valid")(x)
x = Conv2D(64, (3, 3), strides=1, activation="relu")(x)
x = AveragePooling2D(pool_size=(2,2),strides=2, padding="valid")(x)
x = Conv2D(128, (3, 3), strides=1, activation="relu")(x)
x = AveragePooling2D(pool_size=(2,2),strides=2, padding="valid")(x)

x = Flatten()(x)

x = Dense(512, activation="relu")(x)
x = Dropout(0.2)(x)
x = Dense(K, activation="softmax")(x)

model = Model(i, x)

# Visualizando arquitetura da rede
model.summary()
```

Model: "functional"

Layer (type)	Output Shape	Param #
input_layer (InputLayer)	(None, 32, 32, 3)	0
conv2d (Conv2D)	(None, 30, 30, 32)	896
average_pooling2d (AveragePooling2D)	(None, 15, 15, 32)	0
conv2d_1 (Conv2D)	(None, 13, 13, 64)	18,496
average_pooling2d_1 (AveragePooling2D)	(None, 6, 6, 64)	0
conv2d_2 (Conv2D)	(None, 4, 4, 128)	73,856
average_pooling2d_2 (AveragePooling2D)	(None, 2, 2, 128)	0
flatten (Flatten)	(None, 512)	0
dense (Dense)	(None, 512)	262,656
dropout (Dropout)	(None, 512)	0
dense_1 (Dense)	(None, 10)	5,130

Total params: 361,034 (1.38 MB)
Trainable params: 361,034 (1.38 MB)
Non-trainable params: 0 (0.00 B)

```
# Compilar o modelo
model.compile(optimizer="adam", loss="sparse_categorical_crossentropy",
      metrics=["accuracy"])

# Treinando o modelo
r = model.fit(x_train, y_train, validation_data=(x_test, y_test),epochs=15)
```

```
Epoch 1/15
1563/1563 ━━━━━━━━━━━━━━━━━━━━ 18s 8ms/step - accuracy: 0.3411 - loss: 1.7784 - val_accuracy: 0.5201 - val_loss: 1.3315
Epoch 2/15
1563/1563 ━━━━━━━━━━━━━━━━━━━━ 9s 3ms/step - accuracy: 0.5413 - loss: 1.2757 - val_accuracy: 0.6051 - val_loss: 1.0980
Epoch 3/15
1563/1563 ━━━━━━━━━━━━━━━━━━━━ 6s 3ms/step - accuracy: 0.6247 - loss: 1.0578 - val_accuracy: 0.6343 - val_loss: 1.0145
Epoch 4/15
1563/1563 ━━━━━━━━━━━━━━━━━━━━ 4s 3ms/step - accuracy: 0.6633 - loss: 0.9502 - val_accuracy: 0.6646 - val_loss: 0.9588
Epoch 5/15
1563/1563 ━━━━━━━━━━━━━━━━━━━━ 5s 3ms/step - accuracy: 0.6999 - loss: 0.8506 - val_accuracy: 0.7014 - val_loss: 0.8469
Epoch 6/15
1563/1563 ━━━━━━━━━━━━━━━━━━━━ 5s 3ms/step - accuracy: 0.7329 - loss: 0.7605 - val_accuracy: 0.6998 - val_loss: 0.8659
Epoch 7/15
1563/1563 ━━━━━━━━━━━━━━━━━━━━ 5s 3ms/step - accuracy: 0.7512 - loss: 0.7069 - val_accuracy: 0.7155 - val_loss: 0.8162
Epoch 8/15
1563/1563 ━━━━━━━━━━━━━━━━━━━━ 6s 3ms/step - accuracy: 0.7718 - loss: 0.6441 - val_accuracy: 0.7126 - val_loss: 0.8495
Epoch 9/15
1563/1563 ━━━━━━━━━━━━━━━━━━━━ 10s 4ms/step - accuracy: 0.7927 - loss: 0.5895 - val_accuracy: 0.7296 - val_loss: 0.7907
Epoch 10/15
1563/1563 ━━━━━━━━━━━━━━━━━━━━ 5s 3ms/step - accuracy: 0.8098 - loss: 0.5380 - val_accuracy: 0.7463 - val_loss: 0.7479
Epoch 11/15
1563/1563 ━━━━━━━━━━━━━━━━━━━━ 5s 3ms/step - accuracy: 0.8277 - loss: 0.4921 - val_accuracy: 0.7140 - val_loss: 0.8837
Epoch 12/15
1563/1563 ━━━━━━━━━━━━━━━━━━━━ 6s 4ms/step - accuracy: 0.8371 - loss: 0.4607 - val_accuracy: 0.7382 - val_loss: 0.8133
Epoch 13/15
1563/1563 ━━━━━━━━━━━━━━━━━━━━ 5s 3ms/step - accuracy: 0.8517 - loss: 0.4155 - val_accuracy: 0.7451 - val_loss: 0.8007
Epoch 14/15
1563/1563 ━━━━━━━━━━━━━━━━━━━━ 6s 4ms/step - accuracy: 0.8678 - loss: 0.3750 - val_accuracy: 0.7474 - val_loss: 0.8150
Epoch 15/15
1563/1563 ━━━━━━━━━━━━━━━━━━━━ 9s 3ms/step - accuracy: 0.8775 - loss: 0.3414 - val_accuracy: 0.7463 - val_loss: 0.8502
```

```
# Plotar a função de perda, treino e validação
plt.plot(r.history["loss"], label="loss")
plt.plot(r.history["val_loss"], label="val_loss")
plt.legend()
plt.show()
```

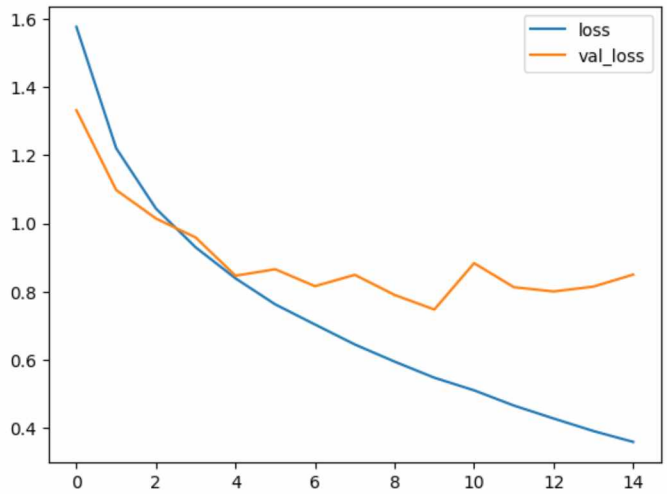


```
# Plotar acurácia, treino e validação
plt.plot(r.history["accuracy"], label="acc")
```

```
plt.plot(r.history["val_accuracy"], label="val_acc")
plt.legend()
plt.show()
```

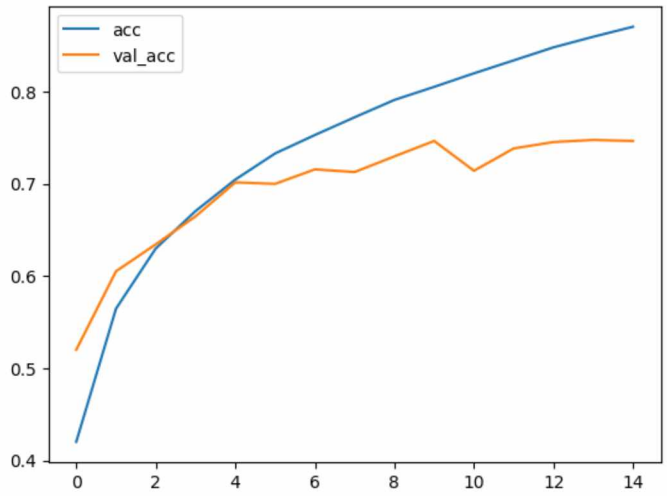


```
# Predições na base de teste
y_pred = model.predict(x_test).argmax(axis=1)

# Matriz de confusão
cm = confusion_matrix(y_test, y_pred)
plot_confusion_matrix(conf_mat=cm, figsize=(7, 7), show_normed=True)
```

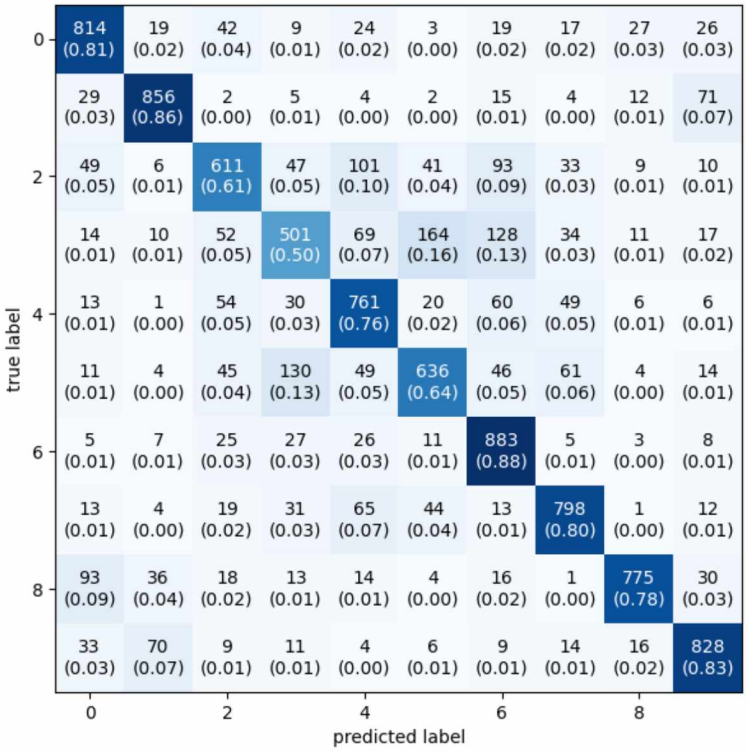

```
# Exemplo de classificação correta
labels= ["airplane", "automobile", "bird", "cat", "deer", "dog",
      "frog", "horse", "ship", "truck"]
classified = np.where(y_pred == y_test)[0]
i = np.random.choice(classified)
plt.imshow(x_test[i], cmap="gray")
plt.title("True label: %s Predicted: %s" % (labels[y_test[i]],
labels[y_pred[i]]))
```

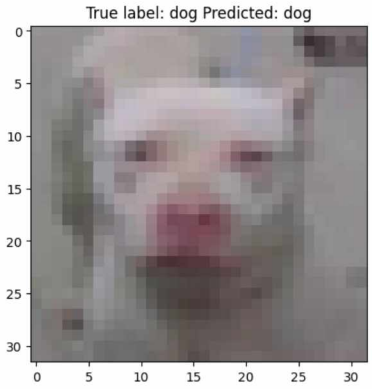


```
# Exemplo de classificação errada
labels= ["airplane", "automobile", "bird", "cat", "deer", "dog",
      "frog", "horse", "ship", "truck"]
misclassified = np.where(y_pred != y_test)[0]
i = np.random.choice(misclassified)
plt.imshow(x_test[i], cmap="gray")
plt.title("True label: %s Predicted: %s" % (labels[y_test[i]],
labels[y_pred[i]]))
```

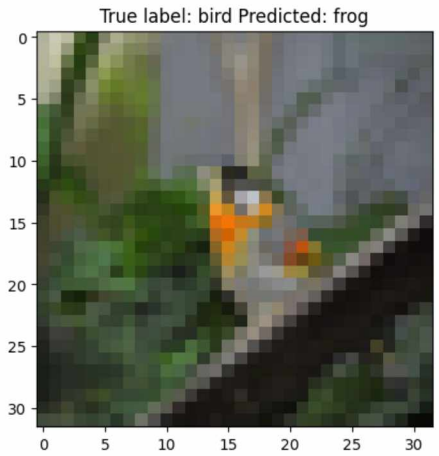

2 Detector de SPAM (RNN)

```
!pip install tensorflow
import tensorflow as tf
```

```
import numpy as np
import matplotlib.pyplot as plt
import pandas as pd
from sklearn.model_selection import train_test_split
from tensorflow.keras.layers import Input, Embedding, LSTM, Dense
from tensorflow.keras.layers import GlobalMaxPooling1D
from tensorflow.keras.models import Model
from tensorflow.keras.preprocessing.sequence import pad_sequences
from tensorflow.keras.preprocessing.text import Tokenizer

!wget http://www.razer.net.br/datasets/spam.csv

df = pd.read_csv("spam.csv", encoding="ISO-8859-1", usecols=['v1',
       'v2']).rename(columns={'v1': 'labels', 'v2': 'data'})
df
```

	labels	data
0	ham	Go until jurong point, crazy.. Available only ...
1	ham	Ok lar... Joking wif u oni...
2	spam	Free entry in 2 a wkly comp to win FA Cup fina...
3	ham	U dun say so early hor... U c already then say...
4	ham	Nah I don't think he goes to usf, he lives aro...
...	...	...
5567	spam	This is the 2nd time we have tried 2 contact u...
5568	ham	Will Ì_ b going to esplanade fr home?
5569	ham	Pity, * was in mood for that. So...any other s...
5570	ham	The guy did some bitching but I acted like i'd...
5571	ham	Rofl. Its true to its name

5572 rows × 2 columns

```
df['b_labels'] = df.labels.map({"ham": 0, "spam": 1})
y = df.b_labels.values
x_train, x_test, y_train, y_test = train_test_split(df.data, y,
       test_size = 0.33)
num_words = 20000
tokenizer = Tokenizer(num_words = num_words)
tokenizer.fit_on_texts(x_train)
sequences_train = tokenizer.texts_to_sequences(x_train)
sequences_test = tokenizer.texts_to_sequences(x_test)
word2index = tokenizer.word_index
V = len(word2index)

print(V)
7180
```

```
data_train = pad_sequences(sequences_train)
T = data_train.shape[1]
data_test = pad_sequences(sequences_test, maxlen=T)

print("data_train.shape:", data_train.shape)
print("data_test.shape:", data_test.shape)

data_train.shape: (3733, 162)
data_test.shape: (1839, 162)

D = 20
M = 5
i = Input(shape=(T,))
x = Embedding(V+1, D)(i)
x = LSTM(M)(x)
x = Dense(1, activation = 'sigmoid')(x)

model = Model(i,x)

model.summary()
```

Model: "functional"

Layer (type)	Output Shape	Param #
input_layer_1 (InputLayer)	(None, 162)	0
embedding_1 (Embedding)	(None, 162, 20)	143,620
lstm_1 (LSTM)	(None, 5)	520
dense_1 (Dense)	(None, 1)	6

Total params: 144,146 (563.07 KB)
Trainable params: 144,146 (563.07 KB)
Non-trainable params: 0 (0.00 B)

```
model.compile(loss='binary_crossentropy', optimizer = 'adam',
      metrics = ['accuracy'])
epochs = 5
r = model.fit(data_train, y_train, epochs = epochs,
      validation_data = (data_test, y_test))
```

```
Epoch 1/5
117/117 ━━━━━━━━━━━━━━━━━━━━ 11s 72ms/step - accuracy: 0.8505 - loss: 0.5173 - val_accuracy: 0.9212 - val_loss: 0.2214
Epoch 2/5
117/117 ━━━━━━━━━━━━━━━━━━━━ 7s 56ms/step - accuracy: 0.9475 - loss: 0.1988 - val_accuracy: 0.9755 - val_loss: 0.1229
Epoch 3/5
117/117 ━━━━━━━━━━━━━━━━━━━━ 8s 72ms/step - accuracy: 0.9826 - loss: 0.1147 - val_accuracy: 0.9853 - val_loss: 0.0848
Epoch 4/5
117/117 ━━━━━━━━━━━━━━━━━━━━ 7s 56ms/step - accuracy: 0.9935 - loss: 0.0701 - val_accuracy: 0.9864 - val_loss: 0.0678
Epoch 5/5
117/117 ━━━━━━━━━━━━━━━━━━━━ 23s 167ms/step - accuracy: 0.9961 - loss: 0.0481 - val_accuracy: 0.9869 - val_loss: 0.0588
```

```
plt.plot(r.history['loss'], label = 'loss')
plt.plot(r.history['val_loss'], label = 'val_loss')
plt.xticks(np.arange(0, epochs, step=1), labels = range(1, epochs+1))
```

```
plt.legend()
plt.show()
```

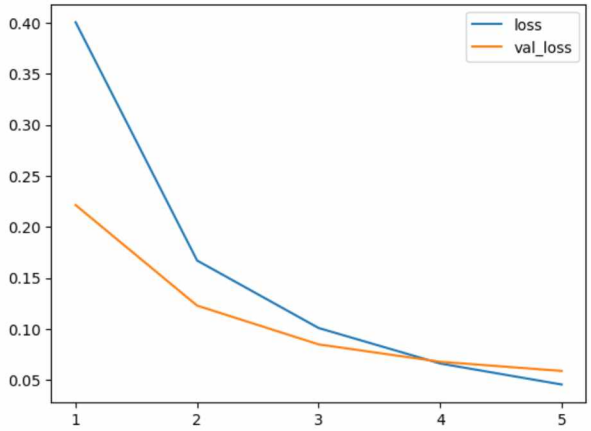


```
plt.plot(r.history['accuracy'], label = 'acuracia')
plt.plot(r.history['val_accuracy'], label = 'val_acc')
plt.xticks(np.arange(0, epochs, step=1), labels = range(1, epochs+1))
plt.legend()
plt.show()
```

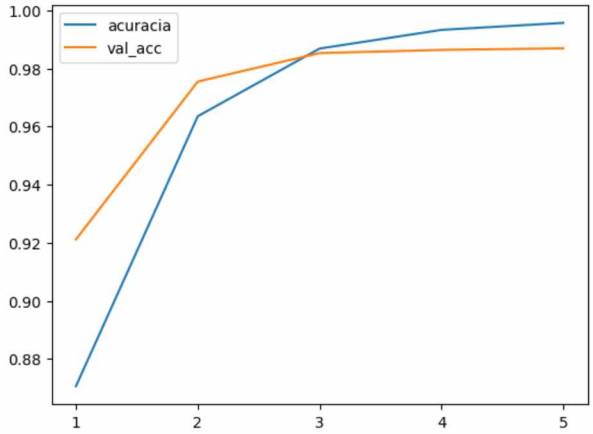


```
texto = "Is your car dirty? Discovery our new product. Free for all. Click
the link."

seq_texto = tokenizer.texts_to_sequences([texto])
data_texto = pad_sequences(seq_texto, maxlen=T)

pred = model.predict(data_texto)
print(pred)
print("Spam" if pred >= 0.5 else 'ok')
```

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 345ms/step
[[0.6511604]]
Spam
```

3 Gerador de Dígitos Fake (GAN)

```
!pip install imageio
!pip install git+https://github.com/tensorflow/docs

import tensorflow as tf
import glob
import imageio
import matplotlib.pyplot as plt
import numpy as np
import os
import PIL
from tensorflow.keras import layers
import time
from tensorflow.keras.losses import BinaryCrossentropy
from tensorflow.keras.optimizers import Adam, SGD, RMSprop
from IPython import display

(train_images, train_labels), (_,_) = tf.keras.datasets.mnist.load_data()

train_images = train_images.reshape(train_images.shape[0], 28, 28,
      1).astype('float32')
train_images = (train_images - 127.5) / 127.5

BUFFER_SIZE = 60000
BATCH_SIZE = 256

train_dataset = tf.data.Dataset.from_tensor_slices(train_images)
train_dataset = train_dataset.shuffle(BUFFER_SIZE).batch(BATCH_SIZE)

def make_generator_model():
  model = tf.keras.Sequential()
  model.add(layers.Dense(7*7*256, use_bias = False, input_shape = (100,)))
  model.add(layers.BatchNormalization())
  model.add(layers.LeakyReLU())
  model.add(layers.Reshape((7,7,256)))
  assert model.output_shape == (None, 7, 7, 256)
  model.add(layers.Conv2DTranspose(128, (5,5), strides=(1,1),
       padding = 'same', use_bias= False))
  assert model.output_shape == (None, 7,7,128)
  model.add(layers.BatchNormalization())
  model.add(layers.LeakyReLU())
```

```
  model.add(layers.Conv2DTranspose(64, (5,5), strides=(2,2),
       padding = 'same', use_bias = False))
  assert model.output_shape == (None, 14, 14, 64)
  model.add(layers.BatchNormalization())
  model.add(layers.LeakyReLU())
  model.add(layers.Conv2DTranspose(1, (5,5), strides=(2,2),
       padding = 'same', use_bias = False))
  assert model.output_shape == (None, 28, 28, 1)
  return model

generator = make_generator_model()
noise = tf.random.normal([1,100])
generated_image = generator(noise, training = False)

plt.imshow(generated_image[0, :, :, 0], cmap = 'gray')
```

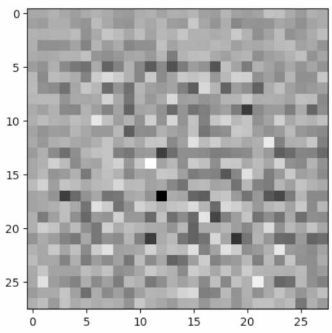


```
def make_discriminator_model():
  model = tf.keras.Sequential()
  model.add(layers.Conv2D(64, (5,5), strides = (2,2),
      padding = 'same', input_shape = [28,28,1]))
  model.add(layers.LeakyReLU())
  model.add(layers.Dropout(0.3))
  model.add(layers.Conv2D(128, (5,5), strides = (2,2), padding = 'same'))
  model.add(layers.LeakyReLU())
  model.add(layers.Dropout(0.3))
  model.add(layers.Flatten())
  model.add(layers.Dense(1))
  return model

discriminator = make_discriminator_model()
decision = discriminator(generated_image)
print(decision)
tf.Tensor([[0.00111132]], shape=(1, 1), dtype=float32)
```

```
cross_entropy = tf.keras.losses.BinaryCrossentropy(from_logits=True)

def discriminator_loss(real_output, fake_output):
  real_loss = cross_entropy(tf.ones_like(real_output), real_output)
  fake_loss = cross_entropy(tf.zeros_like(fake_output), fake_output)
  total_loss = real_loss + fake_loss
  return total_loss

def generator_loss(fake_output):
  return(cross_entropy(tf.ones_like(fake_output), fake_output))

generator_optimizer = tf.keras.optimizers.Adam(1e-4)
discriminator_optimizer = tf.keras.optimizers.Adam(1e-4)

checkpoint_dir = './training_chekcpoints'
checkpoint_prefix = os.path.join(checkpoint_dir, 'ckpt')
checkpoint = tf.train.Checkpoint(generator_optimizer=generator_optimizer,
      discriminator_optimizer = discriminator_optimizer,
      generator=generator, discriminator = discriminator)

EPOCHS = 100
noise_dim = 100
num_example_to_generate = 16
seed = tf.random.normal([num_example_to_generate, noise_dim])

@tf.function
def train_step(images):
  noise = tf.random.normal([BATCH_SIZE, noise_dim])
  with tf.GradientTape() as gen_tape, tf.GradientTape() as disc_tape:
    generated_image = generator(noise, training = True)
    real_output = discriminator(images, training=True)
    fake_output = discriminator(generated_image, training=True)
    gen_loss = generator_loss(fake_output)
    disc_loss = discriminator_loss(real_output, fake_output)

  gradients_of_generator = gen_tape.gradient(gen_loss,
      generator.trainable_variables)
  gradients_of_discriminator = disc_tape.gradient(disc_loss,
      discriminator.trainable_variables)

  generator_optimizer.apply_gradients(zip(gradients_of_generator,
```

```
      generator.trainable_variables))
  discriminator_optimizer.apply_gradients(zip(gradients_of_discriminator,
      discriminator.trainable_variables))

def train(dataset, epochs):
    for epoch in range(epochs):
        start = time.time()
        for image_batch in dataset:
            train_step(image_batch)
        display.clear_output(wait=True)
        generate_and_save_images(generator, epoch + 1, seed)
        if (epoch + 1) % 15 == 0:
            checkpoint.save(file_prefix=checkpoint_prefix)
        print('Time for epoch {} is {} sec'.format(epoch + 1, time.time() -
            start))
    display.clear_output(wait=True)
    generate_and_save_images(generator, epochs, seed)

def generate_and_save_images(model, epoch, test_input):
  predictions = model(test_input, training = False)
  fig = plt.figure(figsize = (4,4))
  for i in range(predictions.shape[0]):
    plt.subplot(4,4,i+1)
    plt.imshow(predictions[i, :, :, 0]*127.5+127.5, cmap='gray')
    plt.axis('off')
  plt.savefig('image_at_epoch_{:04d}.png'.format(epoch))
  plt.show()

train(train_dataset, EPOCHS)
```

```
checkpoint.restore(tf.train.latest_checkpoint(checkpoint_dir))
<tensorflow.python.checkpoint.checkpoint.CheckpointLoadStatus              at
0x7c9942730160>
```

```
import tensorflow_docs.vis.embed as embed
def display_image(epoch_no):
    return PIL.Image.open('image_at_epoch_{:04d}.png'.format(epoch_no))
display_image(EPOCHS)
anim_file = 'dcgan.gif'
with imageio.get_writer(anim_file, mode='I') as writer:
    filenames = glob.glob('image_at_epoch_*.png')
    filenames = sorted(filenames)
    for filename in filenames:
        image = imageio.imread(filename)
        writer.append_data(image)
    if filenames:
        image = imageio.imread(filenames[-1])
        writer.append_data(image)
embed.embed_file(anim_file)
```

4 Tradutor de Textos (Transformer)

```
# INSTALAÇÃO DE PACOTES
!pip uninstall tensorflow
!pip install tensorflow==2.15.0
!pip install tensorflow_datasets
!pip install -U tensorflow-text==2.15.0

# IMPORTAÇÃO DE BIBLIOTECAS
import collections
import logging
import os
import pathlib
import re
import string
import sys
```

```
import time
import numpy as np
import matplotlib.pyplot as plt
import tensorflow_datasets as tfds
import tensorflow_text as text
import tensorflow as tf
logging.getLogger('tensorflow').setLevel(logging.ERROR)

# BASE DE DADOS E TESTE/TREINO
# Carregar a base de dados
examples, metadata = tfds.load('ted_hrlr_translate/pt_to_en',
      with_info=True, as_supervised=True)
train_examples, val_examples = examples['train'], examples['validation']

# Verificar o dataset
for pt_examples, en_examples in train_examples.batch(3).take(1):
  for pt in pt_examples.numpy():
    print(pt.decode('utf-8'))
  print()
  for en in en_examples.numpy():
    print(en.decode('utf-8'))

# TOKENIZAÇÃO E DESTOKENIZAÇÃO
# Tokenização e Destokenização do texto
model_name = "ted_hrlr_translate_pt_en_converter"
tf.keras.utils.get_file(f"{model_name}.zip",
      f"https://storage.googleapis.com/download.tensorflow.org/
      models/{model_name}.zip", cache_dir='.', cache_subdir='',
      extract=True)

# tokenizers.en tokeniza e detokeniza
tokenizers = tf.saved_model.load(model_name)

# PIPELINE DE ENTRADA
# Definindo função para codificar/tokenizar lotes de texto puro
def tokenize_pairs(pt, en):
  pt = tokenizers.pt.tokenize(pt)
  pt = pt.to_tensor()
  en = tokenizers.en.tokenize(en)
  en = en.to_tensor()
  return pt, en
```

```
# Pipeline: processa, embaralha, agrupa os dados, prefetch
BUFFER_SIZE = 20000
BATCH_SIZE = 64

def make_batches(ds):
  return (
    ds
    .cache()
    .shuffle(BUFFER_SIZE)
    .batch(BATCH_SIZE)
    .map(tokenize_pairs, num_parallel_calls=tf.data.AUTOTUNE)
      .prefetch(tf.data.AUTOTUNE))

train_batches = make_batches(train_examples)
val_batches = make_batches(val_examples)

# DEFININDO FUNÇÕES PARA CODIFICAÇÃO POSICIONAL
def get_angles(pos, i, d_model):
  angle_rates = 1 / np.power(10000, (2 * (i//2)) / np.float32(d_model))
  return pos * angle_rates

def positional_encoding(position, d_model):
  angle_rads = get_angles(np.arange(position)[:,
      np.newaxis],np.arange(d_model)[np.newaxis, :], d_model)
  angle_rads[:, 0::2] = np.sin(angle_rads[:, 0::2])
  angle_rads[:, 1::2] = np.cos(angle_rads[:, 1::2])
  pos_encoding = angle_rads[np.newaxis, ...]
  return tf.cast(pos_encoding, dtype=tf.float32)

# CODIFICAÇÃO POSICIONAL
n, d = 2048, 512
pos_encoding = positional_encoding(n, d)
print(pos_encoding.shape)
pos_encoding = pos_encoding[0]

# Arrumar as dimensões
pos_encoding = tf.reshape(pos_encoding, (n, d//2, 2))
pos_encoding = tf.transpose(pos_encoding, (2, 1, 0))
pos_encoding = tf.reshape(pos_encoding, (d, n))
plt.pcolormesh(pos_encoding, cmap='RdBu')
plt.ylabel('Depth')
```

```
plt.xlabel('Position')
plt.colorbar()
plt.show()
```

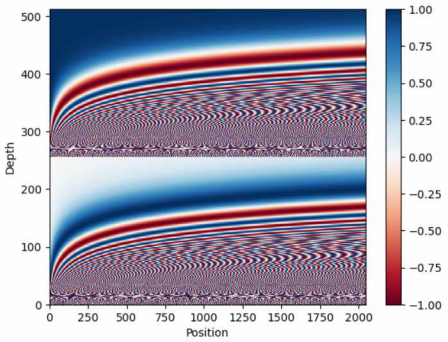


```
# DEFININDO FUNÇÕES PARA MASCARAMENTO POR 0 E 1
def create_padding_mask(seq):
  seq = tf.cast(tf.math.equal(seq, 0), tf.float32)
  return seq[:, tf.newaxis, tf.newaxis, :]

def create_look_ahead_mask(size):
  mask = 1 - tf.linalg.band_part(tf.ones((size, size)), -1, 0)
  return mask

# DEFININDO FUNÇÃO DE ATENÇÃO
def scaled_dot_product_attention(q, k, v, mask):
  matmul_qk = tf.matmul(q, k, transpose_b=True)
  dk = tf.cast(tf.shape(k)[-1], tf.float32)
  scaled_attention_logits = matmul_qk / tf.math.sqrt(dk)
  if mask is not None:
    scaled_attention_logits += (mask * -1e9)
  attention_weights = tf.nn.softmax(scaled_attention_logits, axis=-1)
  output = tf.matmul(attention_weights, v)
  return output, attention_weights

# ATENÇÃO MULTI-CABEÇAS
class MultiHeadAttention(tf.keras.layers.Layer):
  def __init__(self, d_model, num_heads):
    super(MultiHeadAttention, self).__init__()
    self.num_heads = num_heads
    self.d_model = d_model
    assert d_model % self.num_heads == 0
    self.depth = d_model // self.num_heads
    self.wq = tf.keras.layers.Dense(d_model)
```

```
    self.wk = tf.keras.layers.Dense(d_model)
    self.wv = tf.keras.layers.Dense(d_model)
    self.dense = tf.keras.layers.Dense(d_model)

  def split_heads(self, x, batch_size):
    x = tf.reshape(x, (batch_size, -1, self.num_heads, self.depth))
    return tf.transpose(x, perm=[0, 2, 1, 3])

  def call(self, v, k, q, mask):
    batch_size = tf.shape(q)[0]
    q = self.wq(q)
    k = self.wk(k)
    v = self.wv(v)
    q = self.split_heads(q, batch_size)
    k = self.split_heads(k, batch_size)
    v = self.split_heads(v, batch_size)

    scaled_attention, attention_weights = scaled_dot_product_attention(q, k,
      v, mask)
    scaled_attention = tf.transpose(scaled_attention, perm=[0, 2, 1, 3])
    concat_attention = tf.reshape(scaled_attention, (batch_size, -1,
      self.d_model))
    output = self.dense(concat_attention)
    return output, attention_weights

# DEFININDO FUNÇÃO PARA REDE FEED-FORWARD
def point_wise_feed_forward_network(d_model, dff):
  return tf.keras.Sequential([
  tf.keras.layers.Dense(dff,
activation='relu'),tf.keras.layers.Dense(d_model)])

# DEFININDO CLASSE E FUNÇÕES PARA CAMADA DO CODIFICADOR
class EncoderLayer(tf.keras.layers.Layer):
  def __init__(self, d_model, num_heads, dff, rate=0.1):
    super(EncoderLayer, self).__init__()
    self.mha = MultiHeadAttention(d_model, num_heads)
    self.ffn = point_wise_feed_forward_network(d_model, dff)
    self.layernorm1 = tf.keras.layers.LayerNormalization(epsilon=1e-6)
    self.layernorm2 = tf.keras.layers.LayerNormalization(epsilon=1e-6)
    self.dropout1 = tf.keras.layers.Dropout(rate)
    self.dropout2 = tf.keras.layers.Dropout(rate)
```

```
  def call(self, x, training, mask):
    attn_output, _ = self.mha(x, x, x, mask)
    attn_output = self.dropout1(attn_output, training=training)
    out1 = self.layernorm1(x + attn_output)
    ffn_output = self.ffn(out1)
    ffn_output = self.dropout2(ffn_output, training=training)
    out2 = self.layernorm2(out1 + ffn_output)
    return out2

# DEFININDO CLASSE E FUNÇÕES PARA CAMADA DO DECODIFICADOR
class DecoderLayer(tf.keras.layers.Layer):
  def __init__(self, d_model, num_heads, dff, rate=0.1):
    super(DecoderLayer, self).__init__()
    self.mha1 = MultiHeadAttention(d_model, num_heads)
    self.mha2 = MultiHeadAttention(d_model, num_heads)
    self.ffn = point_wise_feed_forward_network(d_model, dff)
    self.layernorm1 = tf.keras.layers.LayerNormalization(epsilon=1e-6)
    self.layernorm2 = tf.keras.layers.LayerNormalization(epsilon=1e-6)
    self.layernorm3 = tf.keras.layers.LayerNormalization(epsilon=1e-6)
    self.dropout1 = tf.keras.layers.Dropout(rate)
    self.dropout2 = tf.keras.layers.Dropout(rate)
    self.dropout3 = tf.keras.layers.Dropout(rate)

  def call(self, x, enc_output, training, look_ahead_mask, padding_mask):
    attn1, attn_weights_block1 = self.mha1(x, x, x, look_ahead_mask)
    attn1 = self.dropout1(attn1, training=training)
    out1 = self.layernorm1(attn1 + x)
    attn2, attn_weights_block2 = self.mha2(enc_output, enc_output,
      out1, padding_mask)
    attn2 = self.dropout2(attn2, training=training)
    out2 = self.layernorm2(attn2 + out1)
    ffn_output = self.ffn(out2)
    ffn_output = self.dropout3(ffn_output, training=training)
    out3 = self.layernorm3(ffn_output + out2)
    return out3, attn_weights_block1, attn_weights_block2

# DEFININDO CLASSE E FUNÇÕES PARA ENCODER
class Encoder(tf.keras.layers.Layer):
  def __init__(self, num_layers, d_model, num_heads, dff,input_vocab_size,
      maximum_position_encoding, rate=0.1):
    super(Encoder, self).__init__()
```

```
    self.d_model = d_model
    self.num_layers = num_layers
    self.embedding = tf.keras.layers.Embedding(input_vocab_size, d_model)
    self.pos_encoding = positional_encoding(maximum_position_encoding,
      self.d_model)
    self.enc_layers = [EncoderLayer(d_model, num_heads, dff, rate) for _ in
      range(num_layers)]
    self.dropout = tf.keras.layers.Dropout(rate)

  def call(self, x, training, mask):
    seq_len = tf.shape(x)[1]
    x = self.embedding(x)
    x *= tf.math.sqrt(tf.cast(self.d_model, tf.float32))
    x += self.pos_encoding[:, :seq_len, :]
    x = self.dropout(x, training=training)
    for i in range(self.num_layers):
      x = self.enc_layers[i](x, training, mask)
    return x

# DEFININDO CLASSE E FUNÇÕES PARA DECODER
class Decoder(tf.keras.layers.Layer):
  def __init__(self, num_layers, d_model, num_heads,
      dff, target_vocab_size,maximum_position_encoding, rate=0.1):
    super(Decoder, self).__init__()
    self.d_model = d_model
    self.num_layers = num_layers
    self.embedding = tf.keras.layers.Embedding(target_vocab_size, d_model)
    self.pos_encoding = positional_encoding(maximum_position_encoding,
      d_model)
    self.dec_layers = [DecoderLayer(d_model, num_heads, dff, rate) for _ in
      range(num_layers)]
    self.dropout = tf.keras.layers.Dropout(rate)

  def call(self, x, enc_output, training, look_ahead_mask, padding_mask):
    seq_len = tf.shape(x)[1]
    attention_weights = {}

    x = self.embedding(x)
    x *= tf.math.sqrt(tf.cast(self.d_model, tf.float32))
    x += self.pos_encoding[:, :seq_len, :]
    x = self.dropout(x, training=training)
```

```
    for i in range(self.num_layers):
      x, block1, block2 = self.dec_layers[i](x, enc_output,
            training,look_ahead_mask, padding_mask)
      attention_weights[f'decoder_layer{i+1}_block1'] = block1
      attention_weights[f'decoder_layer{i+1}_block2'] = block2
    return x, attention_weights

# DEFININDO CLASSE E FUNÇÕES PARA TRANSFORMER
class Transformer(tf.keras.Model):
  def __init__(self, num_layers, d_model, num_heads, dff,
      input_vocab_size,target_vocab_size, pe_input, pe_target, rate=0.1):
    super().__init__()
    self.encoder = Encoder(num_layers, d_model, num_heads, dff,
      input_vocab_size, pe_input, rate)
    self.decoder = Decoder(num_layers, d_model, num_heads, dff,
      target_vocab_size, pe_target, rate)
    self.final_layer = tf.keras.layers.Dense(target_vocab_size)

  def call(self, inputs, training):
    inp, tar = inputs
    enc_padding_mask, look_ahead_mask, dec_padding_mask =
      self.create_masks(inp, tar)
    enc_output = self.encoder(inp, training, enc_padding_mask)
    dec_output, attention_weights = self.decoder(tar, enc_output, training,
      look_ahead_mask, dec_padding_mask)
    final_output = self.final_layer(dec_output)
    return final_output, attention_weights

  def create_masks(self, inp, tar):
    enc_padding_mask = create_padding_mask(inp)
    dec_padding_mask = create_padding_mask(inp)
    look_ahead_mask = create_look_ahead_mask(tf.shape(tar)[1])
    dec_target_padding_mask = create_padding_mask(tar)
    look_ahead_mask = tf.maximum(dec_target_padding_mask, look_ahead_mask)
    return enc_padding_mask, look_ahead_mask, dec_padding_mask

# DEFININDO HIPERPARÂMETROS
num_layers = 4
d_model = 128
dff = 512
num_heads = 8
```

```
dropout_rate = 0.1

# DEFININDO FUNÇÕES PARA OTIMIZADOR
class CustomSchedule(tf.keras.optimizers.schedules.LearningRateSchedule):
  def __init__(self, d_model, warmup_steps=4000):
    super(CustomSchedule, self).__init__()
    self.d_model = d_model
    self.d_model = tf.cast(self.d_model, tf.float32)
    self.warmup_steps = warmup_steps

  def __call__(self, step):
    step = tf.cast(step, tf.float32)
    arg1 = tf.math.rsqrt(step)
    arg2 = step * (self.warmup_steps ** -1.5)
    return tf.math.rsqrt(self.d_model) * tf.math.minimum(arg1, arg2)

learning_rate = CustomSchedule(d_model)
optimizer = tf.keras.optimizers.Adam(learning_rate, beta_1=0.9, beta_2=0.98,
epsilon=1e-9)

# DEFININDO FUNÇÕES DE PERDA E MÉTRICA DE ACURÁCIA
loss_object =
      tf.keras.losses.SparseCategoricalCrossentropy(from_logits = True,
      reduction='none')
def loss_function(real, pred):
  mask = tf.math.logical_not(tf.math.equal(real, 0))
  loss_ = loss_object(real, pred)
  mask = tf.cast(mask, dtype=loss_.dtype)
  loss_ *= mask
  return tf.reduce_sum(loss_)/tf.reduce_sum(mask)

def accuracy_function(real, pred):
  accuracies = tf.equal(real, tf.argmax(pred, axis=2))
  mask = tf.math.logical_not(tf.math.equal(real, 0))
  accuracies = tf.math.logical_and(mask, accuracies)
  accuracies = tf.cast(accuracies, dtype=tf.float32)
  mask = tf.cast(mask, dtype=tf.float32)
  return tf.reduce_sum(accuracies)/tf.reduce_sum(mask)

train_loss = tf.keras.metrics.Mean(name='train_loss')
train_accuracy = tf.keras.metrics.Mean(name='train_accuracy')
```

```
# TREINAMENTO DO MODELO
transformer = Transformer(
  num_layers=num_layers,
  d_model=d_model,
  num_heads=num_heads, dff=dff,
      input_vocab_size=tokenizers.pt.get_vocab_size().numpy(),
      target_vocab_size=tokenizers.en.get_vocab_size().numpy(),
      pe_input=1000, pe_target=1000, rate=dropout_rate)

# CHECKPOINT
checkpoint_path = "./checkpoints/train"
ckpt = tf.train.Checkpoint(transformer=transformer, optimizer=optimizer)
ckpt_manager = tf.train.CheckpointManager(ckpt, checkpoint_path,
      max_to_keep=5)

if ckpt_manager.latest_checkpoint:
  ckpt.restore(ckpt_manager.latest_checkpoint)
  print('Latest checkpoint restored!!')

# PROCESSO DE TREINAMENTO
EPOCHS = 20
train_step_signature = [tf.TensorSpec(shape=(None, None),
      dtype=tf.int64),tf.TensorSpec(shape=(None, None), dtype=tf.int64), ]
@tf.function(input_signature=train_step_signature)

def train_step(inp, tar):
  tar_inp = tar[:, :-1]
  tar_real = tar[:, 1:]
  with tf.GradientTape() as tape:
    predictions, _ = transformer([inp, tar_inp], training = True)
    loss = loss_function(tar_real, predictions)
  gradients = tape.gradient(loss, transformer.trainable_variables)
  optimizer.apply_gradients(zip(gradients,
transformer.trainable_variables))
  train_loss(loss)
  train_accuracy(accuracy_function(tar_real, predictions))

# PROCESSO DE TREINAMENTO
for epoch in range(EPOCHS):
  start = time.time()
  train_loss.reset_state()
```

```
  train_accuracy.reset_state()
  for (batch, (inp, tar)) in enumerate(train_batches):
    train_step(inp, tar)
    if batch % 50 == 0:
      print(f'Epoch {epoch + 1} Batch {batch} Loss {train_loss.result():.4f}
            Accuracy {train_accuracy.result():.4f}')

  if (epoch + 1) % 5 == 0:
    ckpt_save_path = ckpt_manager.save()
    print(f'Saving checkpoint for epoch {epoch+1} at {ckpt_save_path}')

  print(f'Epoch {epoch + 1} Loss {train_loss.result():.4f}
       Accuracy {train_accuracy.result():.4f}')
  print(f'Time taken for 1 epoch: {time.time() - start:.2f} secs\n')
```

```
Epoch 20 Batch 0 Loss 1.4211 Accuracy 0.6914
Epoch 20 Batch 50 Loss 1.3913 Accuracy 0.6889
Epoch 20 Batch 100 Loss 1.3962 Accuracy 0.6890
Epoch 20 Batch 150 Loss 1.4023 Accuracy 0.6882
Epoch 20 Batch 200 Loss 1.4098 Accuracy 0.6870
Epoch 20 Batch 250 Loss 1.4143 Accuracy 0.6865
Epoch 20 Batch 300 Loss 1.4190 Accuracy 0.6858
Epoch 20 Batch 350 Loss 1.4203 Accuracy 0.6853
Epoch 20 Batch 400 Loss 1.4242 Accuracy 0.6844
Epoch 20 Batch 450 Loss 1.4271 Accuracy 0.6838
Epoch 20 Batch 500 Loss 1.4314 Accuracy 0.6831
Epoch 20 Batch 550 Loss 1.4349 Accuracy 0.6823
Epoch 20 Batch 600 Loss 1.4376 Accuracy 0.6820
Epoch 20 Batch 650 Loss 1.4401 Accuracy 0.6816
Epoch 20 Batch 700 Loss 1.4428 Accuracy 0.6814
Epoch 20 Batch 750 Loss 1.4471 Accuracy 0.6804
Epoch 20 Batch 800 Loss 1.4523 Accuracy 0.6797
Saving checkpoint for epoch 20 at ./checkpoints/train/ckpt-4
Epoch 20 Loss 1.4525 Accuracy 0.6797
Time taken for 1 epoch: 97.16 secs
```

```
# DEFININDO FUNÇÕES DO TRADUTOR
class Translator(tf.Module):
  def __init__(self, tokenizers, transformer):
    self.tokenizers = tokenizers
    self.transformer = transformer

  def __call__(self, sentence, max_length=20):
    assert isinstance(sentence, tf.Tensor)
    if len(sentence.shape) == 0:
      sentence = sentence[tf.newaxis]
    sentence = self.tokenizers.pt.tokenize(sentence).to_tensor()
    encoder_input = sentence
    start_end = self.tokenizers.en.tokenize([''])[0]
    start = start_end[0][tf.newaxis]
    end = start_end[1][tf.newaxis]
```

```
    output_array = tf.TensorArray(dtype=tf.int64, size=0, dynamic_size=True)
    output_array = output_array.write(0, start)

    for i in tf.range(max_length):
      output = tf.transpose(output_array.stack())
      predictions, _ = self.transformer([encoder_input, output],
            training=False)
      predictions = predictions[:, -1:, :]
      predicted_id = tf.argmax(predictions, axis=-1)
      output_array = output_array.write(i+1, predicted_id[0])
      if predicted_id == end:
        break
    output = tf.transpose(output_array.stack())
    text = tokenizers.en.detokenize(output)[0]
    tokens = tokenizers.en.lookup(output)[0]
    _, attention_weights = self.transformer([encoder_input, output[:,:-1]],
      training=False)
    return text, tokens, attention_weights

# EFETUANDO UMA TRADUÇÃO
translator = Translator(tokenizers, transformer)
sentence = [["Eu li sobre triceratops na enciclopédia.", "Ela chegou como
      uma chuva de verão.", "Eu li varios livros em minhas férias.",],["O
      tempo passou e só agora eles se deram conta do que perderam.","O onibus
      estava lotado quando passou por aqui.","Ninguem viu o que aconteceu"]]

for txt in sentence:
  for frase in txt:
     translated_text, translated_tokens, attention_weights = translator
            ( tf.constant(frase))
     print(f'{"Prediction":15s}: {translated_text}')
```

```
Prediction     : b'i read about tarizlings in egypt .'
Prediction     : b'she arrived like a rain rainbow .'
Prediction     : b'i read several books on my vacation .'
Prediction     : b"time has just gone back and they ' ve been told when they lost it ."
Prediction     : b'the onebbus was cut when it went on here .'
Prediction     : b'no one saw what happened .'
```

APÊNDICE 9 – BIG DATA

A – ENUNCIADO

Enviar um arquivo PDF contendo uma descrição breve (2 páginas) sobre a implementação de uma aplicação ou estudo de caso envolvendo Big Data e suas ferramentas (NoSQL e NewSQL). Caracterize os dados e Vs envolvidos, além da modelagem necessária dependendo dos modelos de dados empregados.

B – RESOLUÇÃO

Entretenimento Baseado em Dados: Um Estudo de Caso sobre o Sistema de Personalização, Recomendação e Produção da Netflix

A Netflix é uma das maiores e mais influentes empresas de streaming do mundo, contando com milhões de assinantes em mais de 190 países e um catálogo extenso de filmes, séries, documentários e conteúdo original. Mas como uma empresa fundada em 1997 oferecendo um serviço de aluguel de DVDs por correio, evoluiu de maneira significativa ao longo dos anos, tornando-se um dos principais nomes no mercado global de entretenimento? A resposta é simples: atenção especial aos dados de seus clientes.

Desde os anos 2000 a Netflix começou a usar dados dos clientes para aprimorar a experiência de uso de sua plataforma. A abordagem baseada em dados foi desenvolvida para ajudar os clientes a descobrir o que assistir de forma mais rápida e assertiva, tornando a experiência mais personalizada. Por exemplo, se a maioria dos usuários que gostam de doramas também costuma assistir a filmes de drama e comédia romântica, o sistema da Netflix identifica esses padrões e, com base nisso, recomenda conteúdos similares para novos assinantes que começam a assistir doramas.

No entanto, com o crescimento da base de usuários e do volume de dados, a empresa percebeu a necessidade de aprimorar seus modelos de recomendação e escalar sua infraestrutura. Inicialmente, a Netflix usava algoritmos simples para sugerir filmes com base nas avaliações e no histórico de visualização dos usuários. Mas, à medida que a plataforma cresceu, também aumentou a complexidade de seu sistema de recomendações. Para lidar com essa enorme quantidade de dados e melhorar a precisão das sugestões, a empresa adotou ferramentas avançadas, como Hadoop, Apache Spark e AWS, para processar e analisar dados em grande escala.

A primeira parte desse sistema de recomendação começa com a coleta de dados, ou seja, a Netflix coleta dados sobre as interações que seus usuários têm com a plataforma, desde um simples login até interações como pausar e

fechar conteúdos e clicar num link recomendado. Todas essas interações, ou eventos, são processados pelo Apache Kafka e enviados para armazenamento na AWS.

Na AWS, os dados podem ser armazenados de diferentes formas:

- S3: utilizado para armazenar os dados brutos e não estruturados
- Amazon Redshift: utilizado para armazenar dados estruturados

Num primeiro momento os dados brutos são apenas armazenados no S3 e, para processar e manipular esses dados, o Netflix utiliza uma gama de tecnologias como Apache Pig, Spark, Jupiter etc. Parte desses dados manipulados são então armazenados em tecnologias que permitem acesso rápido e performático, como Amazon Redshift.

Possuir dados nesses ambientes é crucial para que tecnologias de visualização de dado, como Tableau, possam ter acesso rápido aos dados. Essas ferramentas permitem que a Netflix oriente suas decisões estratégicas, como direcionamento de orçamento para a aquisição ou produção de novos conteúdos, com base nas tendências de preferências dos usuários e na identificação de nichos de oportunidade a serem explorados.

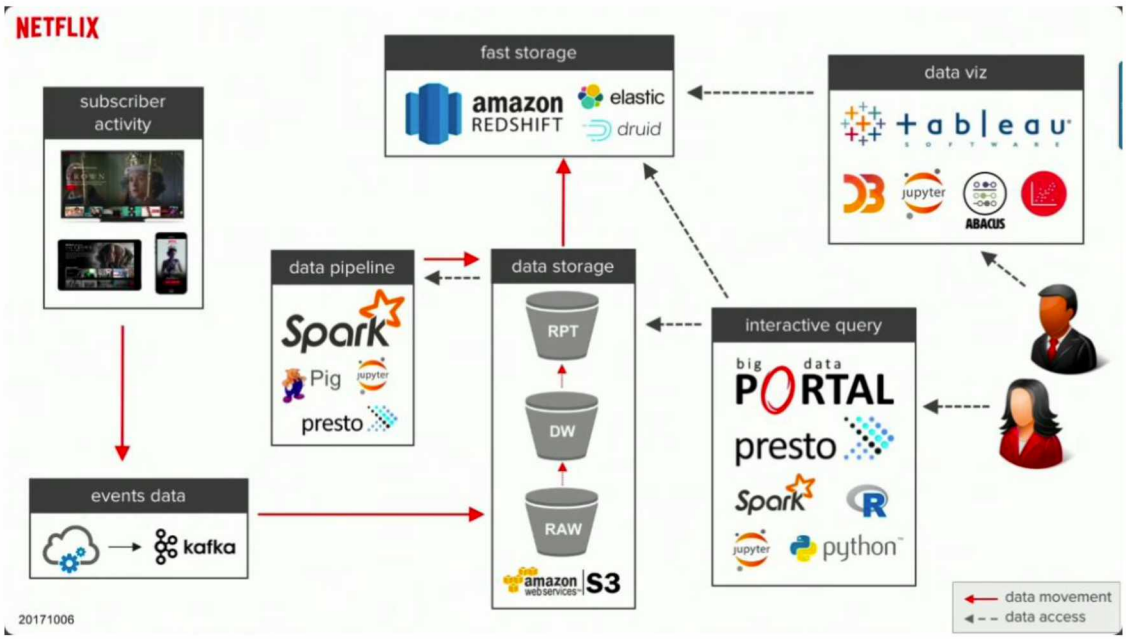

Para personalizar as recomendações, a primeira etapa foi coletar e armazenar uma vasta quantidade de dados. Além dos dados das interações dos usuários, histórico de visualização e avaliações, a Netflix também coleta informações demográficas, como idade, localização e perfil dos usuários.

Após a coleta, o próximo passo é processar esse grande volume de dados, utilizando diversas ferramentas e tecnologias para otimizar o sistema de recomendação:

- Hadoop: usado para processamento em larga escala, especialmente em análises e processamento batch.
- Apache Kafka: permite a transmissão de dados em tempo real, possibilitando que informações sejam coletadas e processadas à medida que os usuários interagem com a plataforma.
- Apache Flink: utilizado para análises em tempo real, permitindo o processamento contínuo de dados e ajustes rápidos nas recomendações.

A análise de dados é uma parte fundamental do processo, pois, com o processamento em tempo real, os modelos de recomendação são constantemente atualizados. Esse método permite que os algoritmos de machine learning identifiquem padrões e preferências comuns entre os usuários de forma rápida e precisa. Como resultado, as recomendações tornam-se cada vez mais relevantes, aumentando o engajamento dos usuários. Quanto mais a Netflix acerta nas recomendações, mais tempo os usuários passam assistindo e interagindo com a plataforma, fornecendo ainda mais dados para a empresa.

Atualmente, a Netflix contém um alto volume de dados, contendo 230 milhões de usuários que geram petabytes de dados a cada dia.

A velocidade em que os dados precisam ser processados é levado em consideração, pois, os dados são processados em tempo real para fornecer as recomendações imediatas e atualizadas.

A Netflix possui uma variedade nos dados, podemos dividi-los em: dados estruturados, que são os dados históricos de visualizações e, também, dados não estruturados como os feedbacks e comentários.

A veracidade diz respeito a qualidade e precisão das recomendações, pois, isso depende muito da qualidade dos dados e dos algoritmos de análises garantindo recomendações relevantes.

Podemos concluir que a Netflix faz uso exemplar de big data para se destacar como uma empresa orientada por dados. Ao priorizar a análise e o entendimento dos dados, a empresa cria experiências únicas e relevantes para seus usuários, aumenta a satisfação e o engajamento deles, e impulsiona a retenção na plataforma.

Referências

https://netflixtechblog.com/
https://www.youtube.com/watch?v=nMyuCdqzpZc

APÊNDICE 10 – VISÃO COMPUTACIONAL

A – ENUNCIADO

1) Extração de Características

Os bancos de imagens fornecidos são conjuntos de imagens de 250x250 pixels de imuno-histoquímica (biópsia) de câncer de mama. No total são 4 classes (0, 1+, 2+ e 3+) que estão divididas em diretórios. O objetivo é classificar as imagens nas categorias correspondentes. Uma base de imagens será utilizada para o treinamento e outra para o teste do treino.

As imagens fornecidas são recortes de uma imagem maior do tipo WSI *(Whole Slide Imaging*) disponibilizada pela Universidade de Warwick (link). A nomenclatura das imagens segue o padrão XX_HER_YYYY.png, onde XX é o número do paciente e YYYY é o número da imagem recortada. Separe a base de treino em 80% para treino e 20% para validação. **Separe por pacientes (XX), não utilize a separação randômica! Pois, imagens do mesmo paciente não podem estar na base de treino e de validação, pois isso pode gerar um viés.** No caso da CNN VGG16 remova a última camada de classificação e armazene os valores da penúltima camada como um vetor de características. Após o treinamento, os modelos treinados devem ser validados na base de teste.

Tarefas:

a) Carregue a base de dados de **Treino.**
b) Crie partições contendo 80% para treino e 20% para validação (atenção aos pacientes).
c) Extraia características utilizando LBP e a CNN VGG16 (gerando um csv para cada extrator).
d) Treine modelos Random Forest, SVM e RNA para predição dos dados extraídos.
e) Carregue a base de **Teste** e execute a tarefa 3 nesta base.
f) Aplique os modelos treinados nos dados de treino
g) Calcule as métricas de Sensibilidade, Especificidade e F1-Score com base em suas matrizes de confusão.
h) Indique qual modelo dá o melhor o resultado e a métrica utilizada

2) Redes Neurais

Utilize as duas bases do exercício anterior para treinar as Redes Neurais Convolucionais VGG16 e a Resnet50. Utilize os pesos pré-treinados (*Transfer Learning*), refaça as camadas *Fully Connected* para o problema de 4 classes. Compare os treinos de 15 épocas com e sem *Data Augmentation*. Tanto a VGG16 quanto a Resnet50 têm como camada de entrada uma imagem 224x224x3, ou seja, uma imagem de 224x224 pixels coloridos (3 canais de cores). Portanto, será necessário fazer uma transformação de 250x250x3 para 224x224x3. Ao fazer o *Data Augmentation* **cuidado** para não alterar demais as cores das imagens e atrapalhar na classificação.

Tarefas:

a) Utilize a base de dados de **Treino** já separadas em treino e validação do exercício anterior
b) Treine modelos VGG16 e Resnet50 adaptadas com e sem *Data Augmentation*
c) Aplique os modelos treinados nas imagens da base de **Teste**
d) Calcule as métricas de Sensibilidade, Especificidade e F1-Score com base em suas matrizes de confusão.
e) Indique qual modelo dá o melhor o resultado e a métrica utilizada

B – RESOLUÇÃO

Preparação para tarefas

```
# Montar google drive
from google.colab import drive
drive.mount('/content/drive')
Mounted at /content/drive

# Caminhos
root = 'drive/MyDrive/IAA011/trabalho/'
train_path = root + 'Train_4cls_amostra/'
test_path = root + 'Test_4cls_amostra/'

# Importações
import os
import pandas as pd
import cv2
import numpy as np
from skimage.feature import local_binary_pattern
from google.colab.patches import cv2_imshow
from tensorflow.keras.applications import VGG16
from tensorflow.keras.applications.vgg16 import preprocess_input
from tensorflow.keras.models import Model
from tensorflow.keras.preprocessing.image import load_img, img_to_array
from keras.optimizers import Adam
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from keras.callbacks import ModelCheckpoint, EarlyStopping
from sklearn.ensemble import RandomForestClassifier
from sklearn import svm, preprocessing
from sklearn.metrics import accuracy_score, multilabel_confusion_matrix,
confusion_matrix, precision_recall_fscore_support
from sklearn.preprocessing import StandardScaler
from sklearn.neural_network import MLPClassifier
from tensorflow.keras.applications import ResNet50
```

```
from tensorflow.keras.layers import Dense, Flatten, Dropout

# Verificar quantidade de amostras por classe para avaliar balanceamento das
amostras
classes = {}
total = 0

# Percorrer diretórios no caminho de treino
for path, _, files in os.walk(train_path):
    # Pega o nome da pasta atual como label
    label = os.path.basename(path)
    # Total de arquivos na pasta
    samples = len(files)
    if samples > 0:
        total += samples
        classes[label] = samples

# Imprime a quantidade de amostras por classe e o total de amostras
print(f'Total por classe: {classes}')
print(f'Total de amostras para treino: {total}')
Total por classe: {'0': 146, '3': 150, '1': 147, '2': 150}
Total de amostras para treino: 593

# Separação base de treino (~80%) e validação (~20%)
# Sempre o primeiro paciente de cada classe vai ser separado para servir
# como validador
train_features = pd.DataFrame(columns=['patientId','imagePath', 'label'])
val_features = pd.DataFrame(columns=['patientId','imagePath','label'])
# Índice para treino
i_train = 0
# Índice para validação
i_val = 0

for path, _, folder in os.walk(train_path):
    if not folder:
      continue
    # Extrair o nome da pasta como label
    label = os.path.basename(path)
    # Referência para o primeiro paciente
    patient_ref = None
```

```
    # Ordenar para garantir consistência na separação
    for image in sorted(folder):
        patient_id = image.split('_')[0]
        if patient_ref is None:
            patient_ref = patient_id

        # Adiciona ao conjunto de validação se for o primeiro
        # paciente da classe
        if patient_id == patient_ref:
            val_features.at[i_val, "patientId"] = patient_id
            val_features.at[i_val, "imagePath"] = os.path.join(train_path,
                   label, image)
            val_features.at[i_val, "label"] = label
            i_val += 1
        else:
            # Adiciona ao conjunto de treino
            train_features.at[i_train, "patientId"] = patient_id
            train_features.at[i_train, "imagePath"] =
                   os.path.join(train_path, label, image)
            train_features.at[i_train, "label"] = label
            i_train += 1

train_features.set_index('patientId', inplace=True)
val_features.set_index('patientId', inplace=True)

train_features_shuffled = train_features.sample(frac=1)
val_features_shuffled = val_features.sample(frac=1)

print(f'Tamanho do conjunto de treino: {train_features_shuffled.shape}')
print(f'Tamanho do conjunto de validação: {val_features_shuffled.shape}')
Tamanho do conjunto de treino: (477, 2)
Tamanho do conjunto de validação: (116, 2)
```

1 Extração de Características

```
# LBP
# Função para calcular o histograma lbp
def get_lbp(img):
    if img is None:
      return None
    # Verifica se a imagem já está em grayscale, se não estiver converte
    # para grayscale
```

```
    if len(img.shape) == 3:
        img = cv2.cvtColor(img, cv2.COLOR_BGR2GRAY)

    # Parâmetros do LBP
    METHOD = 'uniform'
    radius = 3
    n_points = 8 * radius

    # Calcula o histograma do LBP
    lbp_image = local_binary_pattern(img, n_points, radius, METHOD)
    lbp_hist, _ = np.histogram(lbp_image.flatten(), bins=np.arange(0,
       n_points + 3), range=(0, n_points + 2))
    return lbp_hist

# Função para obter valores lbp de todas as imagens
def extract_lbp_features(image_paths):
  lbp_features = []
  for image in image_paths:
    open_image = cv2.imread(image, cv2.IMREAD_GRAYSCALE)
    lbp_value = get_lbp(open_image)
    lbp_features.append(lbp_value)
  return lbp_features

# VGG16
# Carregando modelo VGG16 sem a camada de classificação
base_model = VGG16(weights='imagenet', include_top=False, input_shape=(224,
       224, 3))
model = Model(inputs=base_model.input, outputs=base_model.output)

# Função para converter as imagens de entrada no formato esperado pela VGG16
def preprocess_image(image_path):
    img = load_img(image_path, target_size=(224, 224))
    img_array = img_to_array(img)
    img_array = np.expand_dims(img_array, axis=0)
    img_array = preprocess_input(img_array)
    return img_array

# Função para extrair características de uma única imagem com a VGG16
def get_features_vgg16(image_path):
    img_array = preprocess_image(image_path)
    features = model.predict(img_array)
```

```
    features_flattened = features.flatten()
    return features_flattened

# Função para extrair de todas as imagens
def extract_features_vgg16(image_paths):
    features_list = []
    for image_path in image_paths:
        features = get_features_vgg16(image_path)
        features_list.append(features)
    return np.array(features_list)

# Extraindo características
# Criando X, y de treino
X_train_images = train_features_shuffled['imagePath'].values
y_train = train_features_shuffled['label'].values

# Extraindo características com LBP
lbp_values_array = extract_lbp_features(X_train_images)

# Extraindo características com VGG16
vgg16_values_array = extract_features_vgg16(X_train_images)
```

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 3s 3s/step
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 17ms/step
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 18ms/step
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 16ms/step
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 16ms/step
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 17ms/step
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 16ms/step
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 16ms/step
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 17ms/step
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 16ms/step
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 16ms/step
```

```
# CSV
# Função para gerar o csv
import csv

def save_features_to_csv(image_paths, features, labels, output_file):
    with open(output_file, mode='w', newline='') as file:
        writer = csv.writer(file)
        # Escreve o cabeçalho
        header = ['imagePath'] + [f'feature_{i}' for i in
             range(len(features[0]))] + ['label']
        writer.writerow(header)

        # Escreve as características
        for img, feature, label in zip(image_paths, features, labels):
```

```
            writer.writerow([img] + feature.tolist() + [label])

save_features_to_csv(X_train_images, lbp_values_array, y_train,
       'features_lbp_train.csv')
save_features_to_csv(X_train_images, vgg16_values_array, y_train,
       'features_vgg16_train.csv')

# Treinando modelos Random Forest, SVM e RNA
# Normalizando os dados
scaler = StandardScaler()
norm_features_lbp = scaler.fit_transform(lbp_values_array)
norm_features_vgg16 = scaler.fit_transform(vgg16_values_array)

# Random Forest
clfRandomForest = RandomForestClassifier(random_state=42,
       class_weight="balanced")

# SVM
clfSVM = (svm.SVC(C=15,kernel='rbf',class_weight='balanced',random_state=42,
       decision_function_shape='ovr',probability=True));

# RNA
clfRNA = MLPClassifier(random_state=42, max_iter=500)

# Preparando dados para validação
# Criando X, y de validação
X_val_images = val_features_shuffled['imagePath'].values
y_val = val_features_shuffled['label'].values

# Lendo base de teste
test_features = pd.DataFrame(columns=['patientId', 'imagePath', 'label'])

# Índice para teste
i_test = 0
for path, _, folder in os.walk(test_path):
    if not folder:
        continue

    # Extrair o nome da pasta como label
    label = os.path.basename(path)
```

```
    for image in folder:
        patientId = image.split('_')[0]
        test_features.at[i_test, "patientId"] = patientId
        test_features.at[i_test, "imagePath"] = os.path.join(test_path,
            label, image)
        test_features.at[i_test, "label"] = label
        i_test += 1

test_features.set_index('patientId', inplace=True)
print(f'Tamanho do conjunto de teste: {test_features.shape}')

# Criando X, y de teste
X_test_images = test_features['imagePath'].values
y_test = test_features['label'].values
Tamanho do conjunto de teste: (371, 2)

# LBP
# Treinando modelos pra LBP
clfRandomForest.fit(norm_features_lbp,y_train)
clfSVM.fit(norm_features_lbp,y_train)
clfRNA.fit(norm_features_lbp,y_train)
```

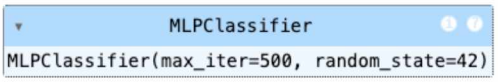


```
# Validação modelos LBP
# Extraindo características com LBP
val_lbp_values_array = extract_lbp_features(X_val_images)
val_norm_features_lbp = scaler.fit_transform(val_lbp_values_array)

# predição com valores de validação
y_val_pred_rf = clfRandomForest.predict(val_norm_features_lbp)
y_val_pred_svm = clfSVM.predict(val_norm_features_lbp)
y_val_pred_rna = clfRNA.predict(val_norm_features_lbp)

print(f'LBP:\nAcurácia com Random Forest {accuracy_score(y_val,
       y_val_pred_rf)}\nAcurácia com SVM {accuracy_score(y_val,
       y_val_pred_svm)}\nAcurácia com RNA {accuracy_score(y_val,
       y_val_pred_rna)}')
LBP:
Acurácia com Random Forest 0.8620689655172413
Acurácia com SVM 0.853448275862069
```

```
Acurácia com RNA 0.8103448275862069

# Testes dos modelos LBP
# Extraindo características com LBP
test_lbp_values_array = extract_lbp_features(X_test_images)
test_norm_features_lbp = scaler.fit_transform(test_lbp_values_array)

# Predição com valores de teste
y_test_pred_rf = clfRandomForest.predict(test_norm_features_lbp)
y_test_pred_svm = clfSVM.predict(test_norm_features_lbp)
y_test_pred_rna = clfRNA.predict(test_norm_features_lbp)

# Random Forest
## Acurácia
rf_accuracy_lbp = accuracy_score(y_test, y_test_pred_rf)
print(f'Acurácia {rf_accuracy_lbp}')

## Matriz de confusão
rf_cm_lbp = confusion_matrix(y_test, y_test_pred_rf)
print(f"Matriz de Confusão:\n{rf_cm_lbp}")

## Sensibilidade, precisão, e F1-score
rf_recall_lbp,        rf_precision_lbp,        rf_f1_lbp,        _        =
precision_recall_fscore_support(y_test, y_test_pred_rf)
print("Sensibilidade por classe:", rf_recall_lbp)
print("Precisão por classe:", rf_precision_lbp)
print("F1-Score por classe:", rf_f1_lbp)
Acurácia 0.7601078167115903
Matriz de Confusão:
[[86  7  8  0]
 [ 6 30 53  1]
 [ 7  6 77  0]
 [ 0  1  0 89]]
Sensibilidade por classe: [0.86868687 0.68181818 0.55797101 0.98888889]
Precisão por classe: [0.85148515 0.33333333 0.85555556 0.98888889]
F1-Score por classe: [0.86       0.44776119 0.6754386  0.98888889]

# SVM
## Acurácia
svm_accuracy_lbp = accuracy_score(y_test, y_test_pred_svm)
print(f'Acurácia {svm_accuracy_lbp}')
```

```
## Matriz de confusão
svm_cm_lbp = confusion_matrix(y_test, y_test_pred_svm)
print(f"Matriz de Confusão:\n{svm_cm_lbp}")

## Sensibilidade, precisão, e F1-score
svm_recall_lbp, svm_precision_lbp, svm_f1_lbp, _ =
      precision_recall_fscore_support(y_test, y_test_pred_svm)
print("Sensibilidade por classe:", svm_recall_lbp)
print("Precisão por classe:", svm_precision_lbp)
print("F1-Score por classe:", svm_f1_lbp)
Acurácia 0.7358490566037735
Matriz de Confusão:
[[72 26  3  0]
 [ 4 36 50  0]
 [ 2  9 79  0]
 [ 0  2  2 86]]
Sensibilidade por classe: [0.92307692 0.49315068 0.58955224 1.        ]
Precisão por classe: [0.71287129 0.4        0.87777778 0.95555556]
F1-Score por classe: [0.80446927 0.44171779 0.70535714 0.97727273]

# RNA
## Acurácia
rna_accuracy_lbp = accuracy_score(y_test, y_test_pred_rna)
print(f'Acurácia {rna_accuracy_lbp}')

## Matriz de confusão
rna_cm_lbp = confusion_matrix(y_test, y_test_pred_rna)
print(f"Matriz de Confusão:\n{rna_cm_lbp}")

## Sensibilidade, precisão, e F1-score
rna_recall_lbp,       rna_precision_lbp,       rna_f1_lbp,       _       =
precision_recall_fscore_support(y_test, y_test_pred_rna)
print("Sensibilidade por classe:", rna_recall_lbp)
print("Precisão por classe:", rna_precision_lbp)
print("F1-Score por classe:", rna_f1_lbp)

Acurácia 0.7520215633423181
Matriz de Confusão:
[[78 20  3  0]
 [ 4 34 52  0]
 [ 2  6 80  2]
```

```
 [ 0  3  0 87]]
Sensibilidade por classe: [0.92857143 0.53968254 0.59259259 0.97752809]
Precisão por classe: [0.77227723 0.37777778 0.88888889 0.96666667]
F1-Score por classe: [0.84324324 0.44444444 0.71111111 0.97206704]

# VGG16
# Treinando modelos VGG16
clfRandomForest.fit(norm_features_vgg16,y_train)
clfSVM.fit(norm_features_vgg16,y_train)
clfRNA.fit(norm_features_vgg16,y_train)
```

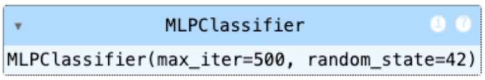


```
# Validação modelos VGG16
# Extraindo características com VGG16
val_vgg16_values_array = extract_features_vgg16(X_val_images)
```

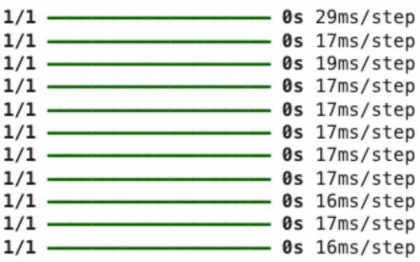


```
val_norm_features_vgg16 = scaler.fit_transform(val_vgg16_values_array)

# Predição com valores de validação
y_val_pred_rf_vgg16 = clfRandomForest.predict(val_norm_features_vgg16)
y_val_pred_svm_vgg16 = clfSVM.predict(val_norm_features_vgg16)
y_val_pred_rna_vgg16 = clfRNA.predict(val_norm_features_vgg16)
print(f'VGG16:\nAcurácia com Random Forest {accuracy_score(y_val,
      y_val_pred_rf_vgg16)}\nAcurácia com SVM {accuracy_score(y_val,
      y_val_pred_svm_vgg16)}\nAcurácia com RNA {accuracy_score(y_val,
      y_val_pred_rna_vgg16)}')
VGG16:
Acurácia com Random Forest 0.5603448275862069
Acurácia com SVM 0.603448275862069
Acurácia com RNA 0.7931034482758621

# Testes dos modelos VGG16
# Extraindo características com VGG16
test_vgg16_values_array = extract_features_vgg16(X_test_images)
```

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 27ms/step
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 25ms/step
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 27ms/step
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 29ms/step
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 24ms/step
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 36ms/step
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 28ms/step
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 29ms/step
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 27ms/step
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 30ms/step
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 31ms/step
```

```
test_norm_features_vgg16 = scaler.fit_transform(test_vgg16_values_array)
# Predição com valores de validação
y_test_pred_rf_vgg16 = clfRandomForest.predict(test_norm_features_vgg16)
y_test_pred_svm_vgg16 = clfSVM.predict(test_norm_features_vgg16)
y_test_pred_rna_vgg16 = clfRNA.predict(test_norm_features_vgg16)

# Random Forest
## Acurácia
rf_accuracy_vgg16 = accuracy_score(y_test, y_test_pred_rf_vgg16)
print(f'Acurácia {rf_accuracy_vgg16}')

## Matriz de confusão
rf_cm_vgg16 = confusion_matrix(y_test, y_test_pred_rf_vgg16)
print(f"Matriz de Confusão:\n{rf_cm_vgg16}")

## Sensibilidade, precisão, e F1-score
rf_recall_vgg16,       rf_precision_vgg16,       rf_f1_vgg16,       _       =
precision_recall_fscore_support(y_test, y_test_pred_rf_vgg16)
print("Sensibilidade por classe:", rf_recall_vgg16)
print("Precisão por classe:", rf_precision_vgg16)
print("F1-Score por classe:", rf_f1_vgg16)
Acurácia 0.7520215633423181
Matriz de Confusão:
[[83 18  0  0]
 [32 34 23  1]
 [ 1  1 72 16]
 [ 0  0  0 90]]
Sensibilidade por classe: [0.71551724 0.64150943 0.75789474 0.8411215 ]
Precisão por classe: [0.82178218 0.37777778 0.8        1.        ]
F1-Score por classe: [0.76497696 0.47552448 0.77837838 0.91370558]

# SVM
## Acurácia
svm_accuracy_vgg16 = accuracy_score(y_test, y_test_pred_svm_vgg16)
```

```
print(f'Acurácia {svm_accuracy_vgg16}')

## Matriz de confusão
svm_cm_vgg16 = confusion_matrix(y_test, y_test_pred_svm_vgg16)
print(f"Matriz de Confusão:\n{svm_cm_vgg16}")

## Sensibilidade, precisão, e F1-score
svm_recall_vgg16, svm_precision_vgg16, svm_f1_vgg16, _ =
      precision_recall_fscore_support(y_test, y_test_pred_svm_vgg16)
print("Sensibilidade por classe:", svm_recall_vgg16)
print("Precisão por classe:", svm_precision_vgg16)
print("F1-Score por classe:", svm_f1_vgg16)
Acurácia 0.77088948787062
Matriz de Confusão:
[[88 13  0  0]
 [22 40 24  4]
 [ 0  0 74 16]
 [ 0  0  6 84]]
Sensibilidade por classe: [0.8        0.75471698 0.71153846 0.80769231]
Precisão por classe: [0.87128713 0.44444444 0.82222222 0.93333333]
F1-Score por classe: [0.83412322 0.55944056 0.7628866  0.86597938]

# RNA
## Acurácia
rna_accuracy_vgg16 = accuracy_score(y_test, y_test_pred_rna_vgg16)
print(f'Acurácia {rna_accuracy_vgg16}')

## Matriz de confusão
rna_cm_vgg16 = confusion_matrix(y_test, y_test_pred_rna_vgg16)
print(f"Matriz de Confusão:\n{rna_cm_vgg16}")

## Sensibilidade, precisão, e F1-score
rna_recall_vgg16,      rna_precision_vgg16,      rna_f1_vgg16,      _      =
precision_recall_fscore_support(y_test, y_test_pred_rna_vgg16)
print("Sensibilidade por classe:", rna_recall_vgg16)
print("Precisão por classe:", rna_precision_vgg16)
print("F1-Score por classe:", rna_f1_vgg16)
Acurácia 0.8652291105121294
Matriz de Confusão:
[[93  8  0  0]
 [16 68  6  0]
```

```
 [ 2  4 70 14]
 [ 0  0  0 90]]
Sensibilidade por classe: [0.83783784 0.85       0.92105263 0.86538462]
Precisão por classe: [0.92079208 0.75555556 0.77777778 1.        ]
F1-Score por classe: [0.87735849 0.8        0.84337349 0.92783505]
```

Conclusão:

Modelo que apresentou melhor desempenho foi o de RNA treinado com as características extraídas pela VGG16, levando em consideração as métricas de acurácia, com 0.86, mas principalmente o F1-score obtido para cada classe do problema, demonstrando um equilíbrio para identificar corretamente os casos positivos e minimizar falsos positivos e falsos negativos.

2 Redes Neurais

```
# Data augmentation
train_generator = ImageDataGenerator(rotation_range=90,
                  brightness_range=[0.4,0.7], width_shift_range=0.5,
                  height_shift_range=0.5, horizontal_flip=True,
                  vertical_flip=True, validation_split=0.2,
                  preprocessing_function=preprocess_input)
test_generator = ImageDataGenerator(preprocessing_function=preprocess_input)

# Quantidade de imagens criadas em cada ciclo
BATCH_SIZE = 32

traingen = train_generator.flow_from_dataframe(train_features_shuffled,
                   x_col='imagePath', y_col='label', target_size=(224,224),
                   batch_size=BATCH_SIZE, shuffle=True, class_mode='sparse',
                   seed=42, subset='training')
validgen = train_generator.flow_from_dataframe(train_features_shuffled,
                   x_col='imagePath', y_col='label',target_size=(224,224),
                   batch_size=BATCH_SIZE, shuffle=True, class_mode='sparse',
                   seed=42, subset='validation')
Found 382 validated image filenames belonging to 4 classes.
Found 95 validated image filenames belonging to 4 classes.

testgen = test_generator.flow_from_dataframe(test_features,
                   x_col='imagePath', y_col='label',target_size=(224,224),
                   batch_size=BATCH_SIZE, shuffle=False, class_mode=None,
                   seed=42,)
Found 371 validated image filenames.
```

```
# VGG16
# Carregando modelo VGG16 sem a camada de classificação
vgg16_base_model = VGG16(weights='imagenet', include_top=False,
             input_shape=(224, 224, 3))

# Não treinar os pesos existentes
for layer in vgg16_base_model.layers:
  layer.trainable = False

# Adicionando as camadas para problema das 4 classes:
x = Flatten()(vgg16_base_model.output)
x = Dense(4, activation='softmax')(x)

# Criando modelo com camadas totalmente conectadas
vgg16_model = Model(inputs=vgg16_base_model.input,outputs=x)

# Compilando o modelo
vgg16_model.compile(optimizer='adam',
loss='sparse_categorical_crossentropy', metrics=['accuracy'])
vgg16_model.summary()
```

Model: "functional_1"

Layer (type)	Output Shape	Param #
input_layer_1 (InputLayer)	(None, 224, 224, 3)	0
block1_conv1 (Conv2D)	(None, 224, 224, 64)	1,792
block1_conv2 (Conv2D)	(None, 224, 224, 64)	36,928
block1_pool (MaxPooling2D)	(None, 112, 112, 64)	0
block2_conv1 (Conv2D)	(None, 112, 112, 128)	73,856
block2_conv2 (Conv2D)	(None, 112, 112, 128)	147,584
block2_pool (MaxPooling2D)	(None, 56, 56, 128)	0
block3_conv1 (Conv2D)	(None, 56, 56, 256)	295,168
block3_conv2 (Conv2D)	(None, 56, 56, 256)	590,080
block3_conv3 (Conv2D)	(None, 56, 56, 256)	590,080
block3_pool (MaxPooling2D)	(None, 28, 28, 256)	0
block4_conv1 (Conv2D)	(None, 28, 28, 512)	1,180,160
block4_conv2 (Conv2D)	(None, 28, 28, 512)	2,359,808
block4_conv3 (Conv2D)	(None, 28, 28, 512)	2,359,808
block4_pool (MaxPooling2D)	(None, 14, 14, 512)	0
block5_conv1 (Conv2D)	(None, 14, 14, 512)	2,359,808
block5_conv2 (Conv2D)	(None, 14, 14, 512)	2,359,808
block5_conv3 (Conv2D)	(None, 14, 14, 512)	2,359,808
block5_pool (MaxPooling2D)	(None, 7, 7, 512)	0
flatten (Flatten)	(None, 25088)	0
dense (Dense)	(None, 4)	100,356

Total params: 14,815,044 (56.51 MB)
Trainable params: 100,356 (392.02 KB)
Non-trainable params: 14,714,688 (56.13 MB)

```
# Resnet50
resnet_base_model = ResNet50(input_shape=(224,224,3), weights='imagenet',
include_top=False)

# Não treinar os pesos existentes
for layer in resnet_base_model.layers:
  layer.trainable = False

# Adicionando as camadas para problema das 4 classes:
x = Flatten()(resnet_base_model.output)
x = Dense(4, activation='softmax')(x)

# Criando modelo com camadas totalmente conectadas
resnet50_model = Model(inputs=resnet_base_model.input,outputs=x)

# Compilando o modelo
resnet50_model.compile(optimizer='adam',
loss='sparse_categorical_crossentropy', metrics=['accuracy'])
resnet50_model.summary()
```

Model: "functional_2"

Layer (type)	Output Shape	Param #	Connected to
input_layer_2 (InputLayer)	(None, 224, 224, 3)	0	-
conv1_pad (ZeroPadding2D)	(None, 230, 230, 3)	0	input_layer_2[0][0]
conv1_conv (Conv2D)	(None, 112, 112, 64)	9,472	conv1_pad[0][0]
conv1_bn (BatchNormalization)	(None, 112, 112, 64)	256	conv1_conv[0][0]
conv1_relu (Activation)	(None, 112, 112, 64)	0	conv1_bn[0][0]
pool1_pad (ZeroPadding2D)	(None, 114, 114, 64)	0	conv1_relu[0][0]
pool1_pool (MaxPooling2D)	(None, 56, 56, 64)	0	pool1_pad[0][0]
conv2_block1_1_conv (Conv2D)	(None, 56, 56, 64)	4,160	pool1_pool[0][0]
conv2_block1_1_bn (BatchNormalization)	(None, 56, 56, 64)	256	conv2_block1_1_conv[0…
conv2_block1_1_relu (Activation)	(None, 56, 56, 64)	0	conv2_block1_1_bn[0][…
conv2_block1_2_conv (Conv2D)	(None, 56, 56, 64)	36,928	conv2_block1_1_relu[0…
conv2_block1_2_bn (BatchNormalization)	(None, 56, 56, 64)	256	conv2_block1_2_conv[0…
conv2_block1_2_relu (Activation)	(None, 56, 56, 64)	0	conv2_block1_2_bn[0][…
conv2_block1_0_conv (Conv2D)	(None, 56, 56, 256)	16,640	pool1_pool[0][0]
conv2_block1_3_conv (Conv2D)	(None, 56, 56, 256)	16,640	conv2_block1_2_relu[0…
conv2_block1_0_bn (BatchNormalization)	(None, 56, 56, 256)	1,024	conv2_block1_0_conv[0…

```
# Data Augmentation
%%time
steps_per_epoch = traingen.samples // BATCH_SIZE
val_steps = validgen.samples // BATCH_SIZE
n_epochs = 10

# Treinamento do Modelo
vgg16_model.fit(traingen, epochs=n_epochs, steps_per_epoch=steps_per_epoch,
                    validation_data=validgen, validation_steps=val_steps,
                    callbacks=None, verbose=True)
```

```
Epoch 1/10
/usr/local/lib/python3.10/dist-packages/keras/src/trainers/data_adapters/py_dataset_adapter.py:121: UserWarning: Your `
  self._warn_if_super_not_called()
11/11 ━━━━━━━━━━━━━━━━━━━━ 43s 2s/step - accuracy: 0.3868 - loss: 7.3268 - val_accuracy: 0.6719 - val_loss: 3.5296
Epoch 2/10
 1/11 ━━━━━━━━━━━━━━━━━━━━ 1s 119ms/step - accuracy: 0.6562 - loss: 3.0308/usr/lib/python3.10/contextlib.py:153: UserWa
  self.gen.throw(typ, value, traceback)
11/11 ━━━━━━━━━━━━━━━━━━━━ 18s 2s/step - accuracy: 0.6562 - loss: 3.0308 - val_accuracy: 0.7097 - val_loss: 2.6398
Epoch 3/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 11s 590ms/step - accuracy: 0.7292 - loss: 2.5661 - val_accuracy: 0.7031 - val_loss: 3.2836
Epoch 4/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 1s 50ms/step - accuracy: 0.7812 - loss: 1.5147 - val_accuracy: 0.7742 - val_loss: 2.2740
Epoch 5/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 10s 494ms/step - accuracy: 0.7618 - loss: 2.5391 - val_accuracy: 0.8594 - val_loss: 1.2864
Epoch 6/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 1s 86ms/step - accuracy: 0.7188 - loss: 2.3250 - val_accuracy: 0.7097 - val_loss: 3.6079
Epoch 7/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 10s 450ms/step - accuracy: 0.7968 - loss: 2.0041 - val_accuracy: 0.8750 - val_loss: 0.9892
Epoch 8/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 1s 53ms/step - accuracy: 0.8438 - loss: 1.0856 - val_accuracy: 0.8387 - val_loss: 0.8129
Epoch 9/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 11s 457ms/step - accuracy: 0.8386 - loss: 1.2825 - val_accuracy: 0.9062 - val_loss: 0.6515
Epoch 10/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 1s 52ms/step - accuracy: 0.8750 - loss: 0.8133 - val_accuracy: 0.8387 - val_loss: 1.5431
CPU times: user 1min 33s, sys: 1.65 s, total: 1min 35s
Wall time: 1min 46s
<keras.src.callbacks.history.History at 0x7bb756956ce0>
```

```
# Treinamento do Modelo
resnet50_model.fit(traingen, epochs=n_epochs, steps_per_epoch =
                    steps_per_epoch, validation_data=validgen,
                    validation_steps=val_steps, callbacks=None,
                    verbose=True)
```

```
Epoch 1/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 31s 1s/step - accuracy: 0.4298 - loss: 12.0453 - val_accuracy: 0.7344 - val_loss: 2.9962
Epoch 2/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 5s 521ms/step - accuracy: 0.6875 - loss: 6.7072 - val_accuracy: 0.6129 - val_loss: 5.0195
Epoch 3/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 9s 421ms/step - accuracy: 0.6856 - loss: 5.9422 - val_accuracy: 0.7969 - val_loss: 3.3152
Epoch 4/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 1s 55ms/step - accuracy: 0.7188 - loss: 5.4231 - val_accuracy: 0.8387 - val_loss: 1.4088
Epoch 5/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 10s 418ms/step - accuracy: 0.7910 - loss: 3.0186 - val_accuracy: 0.8906 - val_loss: 0.8024
Epoch 6/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 1s 52ms/step - accuracy: 0.8438 - loss: 2.3277 - val_accuracy: 0.9032 - val_loss: 1.7724
Epoch 7/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 20s 550ms/step - accuracy: 0.8520 - loss: 2.1586 - val_accuracy: 0.8906 - val_loss: 0.6141
Epoch 8/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 1s 80ms/step - accuracy: 0.8750 - loss: 1.6965 - val_accuracy: 0.9032 - val_loss: 2.7587
Epoch 9/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 20s 426ms/step - accuracy: 0.8847 - loss: 1.5170 - val_accuracy: 0.7969 - val_loss: 2.1935
Epoch 10/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 1s 54ms/step - accuracy: 0.9375 - loss: 0.9702 - val_accuracy: 0.9355 - val_loss: 1.2078
<keras.src.callbacks.history.History at 0x7bb738795d20>
```

```
# Testando os modelos com data augmentation
## VGG16
vgg16_preds = vgg16_model.predict(testgen)
predicted_vgg16_classes = np.argmax(vgg16_preds, axis=1)
```

```
12/12 ━━━━━━━━━━━━━━━━━━━━ 13s 1s/step
```

```
predicted_vgg16_classes = [str(pred) for pred in predicted_vgg16_classes]

## Acurácia
vgg16_accuracy = accuracy_score(y_test, predicted_vgg16_classes)
print(f'Acurácia {vgg16_accuracy}')

## Matriz de confusão
vgg16_cm = confusion_matrix(y_test, predicted_vgg16_classes)
print(f"Matriz de Confusão:\n{vgg16_cm}")

## Sensibilidade, precisão, e F1-score
vgg16_recall, vgg16_precision, vgg16_f1, _ =
      precision_recall_fscore_support(y_test, predicted_vgg16_classes)
print("Sensibilidade por classe:", vgg16_recall)
print("Precisão por classe:", vgg16_precision)
print("F1-Score por classe:", vgg16_f1)

Acurácia 0.7169811320754716
Matriz de Confusão:
[[101   0   0   0]
 [ 49   1  40   0]
 [ 11   3  75   1]
 [  0   0   1  89]]
Sensibilidade por classe: [0.62732919 0.25       0.64655172 0.98888889]
Precisão por classe: [1.         0.01111111 0.83333333 0.98888889]
F1-Score por classe: [0.77099237 0.0212766  0.72815534 0.98888889]

## Resnet50
resnet50_preds = resnet50_model.predict(testgen)
predicted_resnet50_classes = np.argmax(resnet50_preds, axis=1)
```

```
12/12 ━━━━━━━━━━━━━━━━━━━━ 12s 631ms/step
```

```
predicted_resnet50_classes = [str(pred) for pred in
            predicted_resnet50_classes]

## Acurácia
resnet50_accuracy = accuracy_score(y_test, predicted_resnet50_classes)
print(f'Acurácia {resnet50_accuracy}')
```

```
## Matriz de confusão
resnet50_cm = confusion_matrix(y_test, predicted_resnet50_classes)
print(f"Matriz de Confusão:\n{resnet50_cm}")

## Sensibilidade, precisão, e F1-score
resnet50_recall, resnet50_precision, resnet50_f1, _ =
      precision_recall_fscore_support(y_test, predicted_resnet50_classes)
print("Sensibilidade por classe:", resnet50_recall)
print("Precisão por classe:", resnet50_precision)
print("F1-Score por classe:", resnet50_f1)
Acurácia 0.9002695417789758
Matriz de Confusão:
[[101   0   0   0]
 [ 10  77   2   1]
 [  3   9  68  10]
 [  0   0   2  88]]
Sensibilidade por classe: [0.88596491 0.89534884 0.94444444 0.88888889]
Precisão por classe: [1.         0.85555556 0.75555556 0.97777778]
F1-Score por classe: [0.93953488 0.875      0.83950617 0.93121693]

# Testando os modelos com data augmentation
# Gerador sem configurações de data augmentation
train_generator_without_data_augmentation = ImageDataGenerator
      (preprocessing_function=preprocess_input,validation_split=0.2)
traingen_without_data_augmentation =
      train_generator_without_data_augmentation.flow_from_dataframe
      (train_features_shuffled, x_col='imagePath', y_col='label',
      target_size=(224,224), batch_size=BATCH_SIZE, shuffle=True,
      class_mode='sparse', seed=42, subset='training')

validgen_without_data_augmentation =
train_generator_without_data_augmentation.flow_from_dataframe
      (train_features_shuffled, x_col='imagePath', y_col='label',
      target_size=(224,224), batch_size=BATCH_SIZE, shuffle=True,
      class_mode='sparse', seed=42, subset='validation')
Found 382 validated image filenames belonging to 4 classes.
Found 95 validated image filenames belonging to 4 classes.

# Treinamento do Modelo
vgg16_model.fit(traingen_without_data_augmentation, epochs=n_epochs,
                    steps_per_epoch=steps_per_epoch,
```

```
                    validation_data=validgen_without_data_augmentation,
                    validation_steps=val_steps, callbacks=None,
                    verbose=True)
```

```
Epoch 1/10
/usr/local/lib/python3.10/dist-packages/keras/src/trainers/data_adapters/py_dataset_adapter.py:121: UserWarning: Your `PyDataset` c
  self._warn_if_super_not_called()
11/11 ━━━━━━━━━━━━━━━━━━━━ 5s 287ms/step - accuracy: 0.8430 - loss: 2.0016 - val_accuracy: 0.9375 - val_loss: 0.6041
Epoch 2/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 0s 17ms/step - accuracy: 0.9375 - loss: 0.6267 - val_accuracy: 0.9355 - val_loss: 1.4552
Epoch 3/10
/usr/lib/python3.10/contextlib.py:153: UserWarning: Your input ran out of data; interrupting training. Make sure that your dataset
  self.gen.throw(typ, value, traceback)
11/11 ━━━━━━━━━━━━━━━━━━━━ 5s 307ms/step - accuracy: 0.9882 - loss: 0.0455 - val_accuracy: 0.8594 - val_loss: 1.9477
Epoch 4/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 0s 17ms/step - accuracy: 1.0000 - loss: 7.5660e-04 - val_accuracy: 0.8710 - val_loss: 1.7104
Epoch 5/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 9s 234ms/step - accuracy: 0.9942 - loss: 0.0484 - val_accuracy: 0.9688 - val_loss: 0.7103
Epoch 6/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 0s 17ms/step - accuracy: 1.0000 - loss: 2.4996e-06 - val_accuracy: 0.9032 - val_loss: 0.5895
Epoch 7/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 6s 272ms/step - accuracy: 0.9797 - loss: 0.0758 - val_accuracy: 0.9062 - val_loss: 0.7835
Epoch 8/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 0s 17ms/step - accuracy: 0.9688 - loss: 0.1737 - val_accuracy: 0.8710 - val_loss: 2.5369
Epoch 9/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 4s 242ms/step - accuracy: 0.9881 - loss: 0.0797 - val_accuracy: 0.9375 - val_loss: 1.2400
Epoch 10/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 0s 15ms/step - accuracy: 1.0000 - loss: 2.9532e-05 - val_accuracy: 0.9677 - val_loss: 0.0266
<keras.src.callbacks.history.History at 0x7bb7a82d3100>
```

```
# Treinamento do Modelo
resnet50_model.fit(traingen_without_data_augmentation, epochs=n_epochs,
                    steps_per_epoch=steps_per_epoch,
                    validation_data=validgen_without_data_augmentation,
                    validation_steps=val_steps, callbacks=None,
                    verbose=True)
```

```
Epoch 1/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 5s 249ms/step - accuracy: 0.9119 - loss: 1.0787 - val_accuracy: 0.9219 - val_loss: 0.7474
Epoch 2/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 0s 19ms/step - accuracy: 0.9375 - loss: 0.1968 - val_accuracy: 1.0000 - val_loss: 6.8296e-04
Epoch 3/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 4s 227ms/step - accuracy: 0.9787 - loss: 0.0940 - val_accuracy: 0.9531 - val_loss: 1.0861
Epoch 4/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 1s 45ms/step - accuracy: 0.9688 - loss: 0.2476 - val_accuracy: 0.9355 - val_loss: 0.5688
Epoch 5/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 5s 206ms/step - accuracy: 0.9849 - loss: 0.0410 - val_accuracy: 0.9688 - val_loss: 0.6690
Epoch 6/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 0s 18ms/step - accuracy: 1.0000 - loss: 3.7253e-08 - val_accuracy: 1.0000 - val_loss: 0.0011
Epoch 7/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 4s 202ms/step - accuracy: 0.9973 - loss: 0.0095 - val_accuracy: 0.9688 - val_loss: 0.6251
Epoch 8/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 0s 18ms/step - accuracy: 1.0000 - loss: 2.7678e-06 - val_accuracy: 0.9677 - val_loss: 0.0418
Epoch 9/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 4s 229ms/step - accuracy: 1.0000 - loss: 3.5569e-05 - val_accuracy: 0.9688 - val_loss: 0.0621
Epoch 10/10
11/11 ━━━━━━━━━━━━━━━━━━━━ 0s 27ms/step - accuracy: 1.0000 - loss: 2.0794e-04 - val_accuracy: 0.9355 - val_loss: 1.6350
<keras.src.callbacks.history.History at 0x7bb730108940>
```

```
# Testando os modelos
# VGG16 Sem Data augmentation
vgg16_preds_without = vgg16_model.predict(testgen)
predicted_vgg16_without_classes = np.argmax(vgg16_preds_without, axis=1)

predicted_vgg16_without_classes = [str(pred) for pred in
      predicted_vgg16_without_classes]

## Acurácia
vgg16_accuracy_without =
      accuracy_score(y_test, predicted_vgg16_without_classes)
print(f'Acurácia {vgg16_accuracy_without}')
```

```
## Matriz de confusão
vgg16_cm_without = confusion_matrix(y_test, predicted_vgg16_without_classes)
print(f"Matriz de Confusão:\n{vgg16_cm_without}")
## Sensibilidade, precisão, e F1-score
vgg16_recall_without,  vgg16_precision_without,  vgg16_f1_without,  _  =
precision_recall_fscore_support(y_test, predicted_vgg16_without_classes)
print("Sensibilidade por classe:", vgg16_recall_without)
print("Precisão por classe:", vgg16_precision_without)
print("F1-Score por classe:", vgg16_f1_without)

Acurácia 0.7601078167115903
Matriz de Confusão:
[[93  6  2  0]
 [13 13 64  0]
 [ 0  0 87  3]
 [ 0  0  1 89]]
Sensibilidade por classe: [0.87735849 0.68421053 0.56493506 0.9673913 ]
Precisão por classe: [0.92079208 0.14444444 0.96666667 0.98888889]
F1-Score por classe: [0.89855072 0.23853211 0.71311475 0.97802198]

# Resnet50 Sem Data augmentation
resnet50_preds_without = resnet50_model.predict(testgen)
predicted_resnet50_without_classes  =  np.argmax(resnet50_preds_without,
axis=1)
12/12 ━━━━━━━━━━━━━━━━━━━━ 3s 223ms/step

predicted_resnet50_without_classes  =  [str(pred)  for  pred  in
predicted_resnet50_without_classes]

## Acurácia
resnet50_accuracy_without  =  accuracy_score(y_test,
predicted_resnet50_without_classes)
print(f'Acurácia {resnet50_accuracy_without}')

## Matriz de confusão
resnet50_cm_without  =  confusion_matrix(y_test,
predicted_resnet50_without_classes)
print(f"Matriz de Confusão:\n{resnet50_cm_without}")

## Sensibilidade, precisão, e F1-score
```

```
resnet50_recall_without, resnet50_precision_without, resnet50_f1_without, _
      = precision_recall_fscore_support(y_test,
      predicted_resnet50_without_classes)
print("Sensibilidade por classe:", resnet50_recall_without)
print("Precisão por classe:", resnet50_precision_without)
print("F1-Score por classe:", resnet50_f1_without)

Acurácia 0.9191374663072777
Matriz de Confusão:
[[86 15  0  0]
 [ 1 87  2  0]
 [ 0  4 83  3]
 [ 0  0  5 85]]
Sensibilidade por classe: [0.98850575 0.82075472 0.92222222 0.96590909]
Precisão por classe: [0.85148515 0.96666667 0.92222222 0.94444444]
F1-Score por classe: [0.91489362 0.8877551  0.92222222 0.95505618]
```

Conclusão:

O modelo que apresentou melhor desempenho foi o do Resnet50 treinado sem dados provenientes de data augmentation. As métricas consideradas foram as de acurácia, com 0.91, mas principalmente o F1-score obtido para cada classe do problema, demonstrando um equilíbrio para identificar corretamente os casos positivos e minimizar falsos positivos e falsos negativos.

APÊNDICE 11 – ASPECTOS FILOSÓFICOS E ÉTICOS DA IA

A – ENUNCIADO

Título do Trabalho: "Estudo de Caso: Implicações Éticas do Uso do ChatGPT"

Trabalho em Grupo: O trabalho deverá ser realizado em grupo de alunos de no máximo seis (06) integrantes.

Objetivo do Trabalho: Investigar as implicações éticas do uso do ChatGPT em diferentes contextos e propor soluções responsáveis para lidar com esses dilemas.
Parâmetros para elaboração do Trabalho:

1. Relevância Ética: O trabalho deve abordar questões éticas significativas relacionadas ao uso da inteligência artificial, especialmente no contexto do ChatGPT. Os alunos devem identificar dilemas éticos relevantes e explorar como esses dilemas afetam diferentes partes interessadas, como usuários, desenvolvedores e a sociedade em geral.
2. Análise Crítica: Os alunos devem realizar uma análise crítica das implicações éticas do uso do ChatGPT em estudos de caso específicos. Eles devem examinar como o algoritmo pode influenciar a disseminação de informações, a privacidade dos usuários e a tomada de decisões éticas. Além disso, devem considerar possíveis vieses algorítmicos, discriminação e questões de responsabilidade.
3. Soluções Responsáveis: Além de identificar os desafios éticos, os alunos devem propor soluções responsáveis e éticas para lidar com esses dilemas. Isso pode incluir sugestões para políticas, regulamentações ou práticas de design que promovam o uso responsável da inteligência artificial. Eles devem considerar como essas soluções podem equilibrar os interesses de diferentes partes interessadas e promover valores éticos fundamentais, como transparência, justiça e privacidade.
4. Colaboração e Discussão: O trabalho deve envolver discussões em grupo e colaboração entre os alunos. Eles devem compartilhar ideias, debater diferentes pontos de vista e chegar a conclusões informadas através do diálogo e da reflexão mútua. O estudo de caso do ChatGPT pode servir como um ponto de partida para essas discussões, incentivando os alunos a aplicar conceitos éticos e legais aprendidos ao analisar um caso concreto.
5. Limite de Palavras: O trabalho terá um limite de 6 a 10 páginas teria aproximadamente entre 1500 e 3000 palavras.
6. Estruturação Adequada: O trabalho siga uma estrutura adequada, incluindo introdução, desenvolvimento e conclusão. Cada seção deve ocupar uma parte proporcional do total de páginas, com a introdução e a conclusão ocupando menos espaço do que o desenvolvimento.
7. Controle de Informações: Evitar incluir informações desnecessárias que possam aumentar o comprimento do trabalho sem contribuir significativamente para o conteúdo. Concentre-se em informações relevantes, argumentos sólidos e evidências importantes para apoiar sua análise.

8. Síntese e Clareza: O trabalho deverá ser conciso e claro em sua escrita. Evite repetições desnecessárias e redundâncias. Sintetize suas ideias e argumentos de forma eficaz para transmitir suas mensagens de maneira sucinta.

9. Formatação Adequada: O trabalho deverá ser apresentado nas normas da ABNT de acordo com as diretrizes fornecidas, incluindo margens, espaçamento, tamanho da fonte e estilo de citação. Deve-se seguir o seguinte template de arquivo: hfps://bibliotecas.ufpr.br/wp-content/uploads/2022/03/template-artigo-de-periodico.docx

B – RESOLUÇÃO

RESUMO

A inteligência artificial (IA), desde sua concepção em 1956, tem evoluído rapidamente, especialmente na forma de IA generativa, que cria conteúdos como texto, imagem e áudio baseados em dados de treinamento. O ChatGPT, principal exemplo de IA generativa, exemplifica o potencial e os desafios éticos dessa tecnologia. Treinado com vastos conjuntos de dados da internet, levanta diversas questões éticas, como consentimento dos dados utilizados, preconceito ocasionado por viés algorítmico e facilidade na criação de fake news. Para mitigar esses problemas, propõem-se políticas de transparência e consentimento para o uso de dados, auditorias de viés algorítmico e educação em ética para desenvolvedores. Além disso, medidas de verificação de conteúdo e políticas de alfabetização midiática são necessárias para combater a disseminação de fake news. Em conclusão, apesar dos benefícios significativos do ChatGPT, é essencial abordar suas implicações éticas de maneira cuidadosa.

Palavras-chave: inteligência artificial. inteligência artificial generativa. ética. viés. privacidade.

ABSTRACT

Artificial intelligence (AI), since its conception in 1956, has rapidly evolved, especially in the form of generative AI, which creates content such as text, images, and audio based on training data. ChatGPT, a prominent example of generative AI, exemplifies both the potential and ethical challenges of this technology. Trained on vast datasets from the internet, it raises various ethical questions, including consent for data used, bias introduced by algorithmic bias, and ease of creating fake news. To mitigate these issues, proposed solutions include transparency and consent policies for data usage, algorithmic bias audits, and ethics education for developers. Additionally, content verification measures and media literacy policies are necessary to combat the spread of fake news. In conclusion, despite the

significant benefits of ChatGPT, addressing its ethical implications carefully is essential.

Keywords: artificial intelligence. generative artificial intelligence. ethics. bias. Privacy.

1 Introdução

O termo "inteligência artificial" (IA) foi cunhado em 1956, durante uma conferência na Universidade de Dartmouth promovida por John McCarthy, Marvin Minsky, Nathaniel Rochester e Claude Shannon. Desde então, a definição de IA tem sido objeto de debate, mas geralmente se refere à capacidade de máquinas e sistemas computacionais de executar tarefas que normalmente exigiriam a inteligência humana. Alternativamente, IA pode ser entendida como a área de estudo que busca construir agentes inteligentes capazes de realizar a melhor ação possível em uma dada situação1. Exemplos de tarefas e agentes inteligentes incluem reconhecimento de voz, reconhecimento de imagens, aprendizado de padrões, diagnóstico médico, veículos autônomos e recomendação de conteúdo.

Recentemente, um subcampo da IA tem ganhado destaque: a IA generativa. A IA generativa representa sistemas capazes de criar novos conteúdos, seja texto, imagem ou áudio, baseados em dados de treinamento. Para alcançar esses resultados, a IA generativa utiliza aprendizado de máquina, em particular redes neurais profundas. O sucesso no uso das redes neurais profundas foi viabilizado pelos avanços na capacidade de processamento e no desenvolvimento de hardware, resultando em processadores mais rápidos e eficientes, como GPUs (unidades de processamento gráfico) e TPUs (unidades de processamento tensorial), que permitem que sistemas de IA realizem cálculos complexos em velocidades sem precedentes.

As grandes companhias de tecnologia, conhecidas como Big Tech, têm investido intensamente em pesquisas para o avanço das inteligências artificiais (IA). As estratégias de coleta de dados e estudo do comportamento humano no meio digital estão cada vez mais sofisticadas, permitindo a sugestão e direcionamento de produtos e serviços com grande eficiência. Os usuários de mídias sociais e da internet em geral tornaram-se produtos valiosos, disputados pelas grandes companhias, gerando uma competição feroz entre as Big Tech e impulsionando a evolução tecnológica de forma exponencial.

No entanto, essa evolução tecnológica supera a capacidade da sociedade tradicional de acompanhá-la com suas leis e regras. Novas tecnologias introduzem vieses complexos, exigindo atenção contínua de governos, órgãos reguladores e sociedade civil para assegurar os direitos e padrões éticos existentes. Entre os desafios estão a proteção da propriedade intelectual, a

privacidade dos dados pessoais, os direitos humanos, a criação de notícias falsas (fake news) por algoritmos inteligentes e os vieses decorrentes do mau uso da tecnologia. O uso do ChatGPT, devido à sua popularidade e rápida ascensão2, exemplifica algumas dessas implicações éticas. Este estudo de caso explora as implicações éticas do uso do ChatGPT, destacando a importância de considerar aspectos como privacidade dos usuários e de seus dados, viés e impacto social.

2 Desenvolvimento

O ChatGPT, desenvolvido pela OpenAI3, é o exemplo mais conhecido de IA generativa. Ele pode ser definido como um Modelo de Linguagem de Grande Porte, projetado para o processamento de linguagem natural. Esse tipo de modelo é exposto a quantidades massivas de dados para aprender os padrões estatísticos da linguagem, permitindo que ele "gere" novos textos e sequências de palavras com base na probabilidade de como um humano usaria as palavras em um dado contexto.

De acordo com estimativas do banco de investimento UBS2, o ChatGPT conseguiu alcançar mais de 100 milhões de usuários mensais ativos em menos de três meses, marca que o transformou no aplicativo com o mais rápido crescimento na história. Entretanto, essa rápida adoção levanta questões éticas que não podem ser desconsideradas.

Para compreender os padrões linguísticos e, mais recentemente, ser capaz de processar entradas multimodais, ou seja, texto e imagem, o ChatGPT demandou um grande volume de dados. Uma das primeiras questões éticas levantadas diz respeito à proveniência desses dados. Os dados utilizados para treinar modelos como o ChatGPT são, em sua maioria, oriundos de conteúdos públicos da internet. Mas, apesar de estar disponível publicamente, os autores/donos de tais conteúdos não deram consentimento explícito ao ChatGPT. Eles podem até ter concordado com os termos de uso das plataformas em que originalmente postaram conteúdo, mas não imaginaram que, no futuro, seus materiais seriam utilizados para treinar e até mesmo servir de base para IAs generativas. Até que ponto algo que está disponível publicamente e gratuitamente na internet pode ser utilizado, sem consentimento direto dos autores, por empresas privadas no desenvolvimento e melhoria de tecnologias que eventualmente vão gerar lucros para as mesmas?

Esse questionamento se amplia pois, recentemente, a Meta, empresa por traz de aplicativos como Instagram, Facebook e Whatsapp, adicionou uma seção à sua política de privacidade do Instagram para que os usuários possam optar ou não em fornecer suas postagens públicas como fonte de dados para treinamento de Ias generativas da Meta4. Ou seja, os usuários de aplicações da Meta vão ter a chance de recusar o uso de seus dados, mas como fica o

direito de escolha frente a outros modelos de IA generativa que simplesmente afirmam usar dados compartilhados publicamente na internet? Os usuários saberão algum dia que seus conteúdos foram usados por esses modelos?

Outro caso recente envolvendo IA generativa e suposto uso não autorizado de dados de terceiros é o da Associação Americana da Indústria de Gravação (Recording Industry Assoiation of America - RIAA) que entrou com processos contra duas empresas do ramo de IA generativa para música, a Udio e a Suno. A RIAA alega que estas empresas fizeram uso de uma quantidade massiva de músicas protegidas por direitos autorais para conseguir treinar seus modelos5. Caso a RIAA ganhe a causa, pode conseguir abrir precedentes legais relevantes contra casos similares, demonstrando para empresas de IA generativa que elas não podem simplesmente se apropriar de material disponível online para suprir a considerável quantidade de dados necessárias para treinar seus modelos.

Outra questão ética envolvendo dados diz respeito à possível introdução de viés algoritmo, visto que os dados são selecionados para o treinamento, ou seja, a imparcialidade do modelo resultante do treinamento depende dos dados apresentados a ele. Caso os dados selecionados sejam preconceituosos ou desiguais entre diferentes grupos, ou ainda, tenha ocorrido processo de rotulação manual tendenciosa, o modelo vai incorporar isso e acabar replicando esses vieses, impactando na desejada neutralidade algorítmica.

A simplicidade no uso de ferramentas de IA generativa, como o ChatGPT, onde o usuário apenas escreve num prompt de comando e rapidamente é respondido com textos ou imagens, em comparação com métodos "antigos" de obter conteúdo generativo, que exigia conhecimento em programação e técnicas de inteligência artificial, ou de editores de fotos, para caso das imagens, levanta outra questão ética: A facilidade, e velocidade, na criação de conteúdos fantasiosos que podem servir como fonte de notícias falsas, as famosas fake news.

A sofisticação dos conteúdos obtidos com ChatGPT dificulta a capacidade de distinguir entre o que é real e o que não é, assim, conteúdos falsos gerados dessa forma podem rapidamente serem distribuídos entre a população, contribuindo para enfraquecimento na confiança pública nas fontes de informação e levando a uma sociedade "informada" por pós verdade.

As implicações éticas em torno do uso do ChatGPT e outras IAs generativas constituem um campo vasto. Este trabalho optou por discutir questões relacionadas à origem dos dados utilizados no treinamento dos modelos de IA, os riscos ideológicos introduzidos durante esse processo e a facilidade na geração de notícias falsas. A seguir, serão apresentadas possíveis soluções para mitigar esses problemas.

Primeiramente, a respeito da privacidade e consentimento dos dados. É imprescindível a implementação de políticas de transparência que informem aos

usuários sobre como seus dados poderão ser utilizados para treinamento de modelos de IA. Além disso, assim como a iniciativa da Meta, oferecer uma opção para que o usuário informe que não permite que seus dados sejam usados para este fim.

Com relação ao problema do viés algorítmico, é necessário garantir que os conjuntos de dados utilizados nos treinamentos sejam diversos, garantindo assim representatividade desses dados. Outra medida aplicável para mitigar o viés é a realização de auditorias, buscando identificação e correção de possíveis vieses. Além disso, a capacitação dos desenvolvedores e pesquisadores em boas práticas éticas aplicadas à IA pode contribuir para que os vieses sejam reduzidos ainda na fase de desenvolvimento.

O combate à disseminação de fake news e conteúdos enganosos de modo geral demanda tanto esforços por parte das empresas por trás dos modelos de IA quanto das redes sociais e do governo. As empresas devem implementar ferramentas, ou consumir de empresas terceiras, para verificar e monitorar a qualidade e a veracidade dos conteúdos gerados por seus modelos. Já as plataformas de redes sociais devem sinalizar conteúdos potencialmente falsos ou enganosos, ou no mínimo, mencionar quanto a geração da resposta/conteúdo por um mecanismo de inteligência artificial. Por sua vez, o governo deve promover políticas de alfabetização midiática à população, capacitando as pessoas a discernirem entre informações confiáveis e falsas, sem serem influenciadas por crenças pessoais e focando, em especial, na educação infantil, como meio de desenvolver uma geração de pessoas mais bem preparada para uso dos recursos cibernéticos.

Resumindo, o enfrentamento das implicações éticas relacionadas ao ChatGPT exige um esforço conjunto entre desenvolvedores, pesquisadores, empresas, órgão reguladores e população em geral.

3 Conclusão

O rápido crescimento das tecnologias de informação e comunicação traz benefícios, mas também desafios para salvaguardar os direitos humanos e a privacidade. A disseminação da IA, acessível a grande parte da população mundial, levanta questões sobre os desafios enfrentados pela sociedade informacional. Compreender e tratar esses desafios éticos e morais é urgente e necessário. Acompanhando a evolução tecnológica e garantindo que regras éticas estejam atualizadas, podemos evitar resultados ineficazes ou obsoletos. O envolvimento de reguladores, desenvolvedores de tecnologia, a sociedade e governos é essencial para criar regras que abranjam e arbitrem todos os interesses comuns. Além disso, é necessário adaptar os padrões éticos para a sociedade informacional, considerando o uso das tecnologias desde a

infância e a inclusão de gerações anteriores menos familiarizadas com essas inovações.

Referências

1. RUSSEL, S.; NORVIG, P. Artificial Intelligence: A modern approach. Ed. Prentice-Hall, Egnlewood Cliffs, 1995.
2. AI Business - UBS: ChatGPT May Be the Fastest Growing App of All Time. Disponível em: https://aibusiness.com/nlp/ubs-chatgpt-is-the-fastest-growing-app-of-all-time. Acesso em 16 jun. 2024.
3. OpenAI - What is ChatGPT?. Disponível em: https://help.openai.com/en/articles/6783457-what-is-chatgpt. Acesso em 16 jun.2024.
4. Aos Fatos - Como impedir que a Meta use seus dados para alimentar modelos de IA. Disponível em: https://www.aosfatos.org/noticias/como-impedir-uso-dados-pessoais-ia-meta-facebook/. Acesso em 21 jun. 2024.
5. Variety - Major Labels Sue AI Music Services Suno and Udio for Copyright Infringement. Disponível em: https://variety.com/2024/music/news/record-labels-sue-ai-music-services-suno-and-udio-copyright-infringement-1236045366/. Acesso em 25jun. 2024.

APÊNDICE 12 – GESTÃO DE PROJETOS DE IA

A – ENUNCIADO

1 Objetivo

Individualmente, ler e resumir – seguindo o *template* fornecido – **um** dos artigos abaixo:

AHMAD, L.; ABDELRAZEK, M.; ARORA, C.; BANO, M; GRUNDY, J. Requirements practices and gaps when engineering human-centered Artificial Intelligence systems. Applied Soft Computing. 143. 2023. DOI https://doi.org/10.1016/j.asoc.2023.110421

NAZIR, R.; BUCAIONI, A.; PELLICCIONE, P.; Architecting ML-enabled systems: Challenges, best practices, and design decisions. The Journal of Systems & Software. 207. 2024. DOI https://doi.org/10.1016/j.jss.2023.111860

SERBAN, A.; BLOM, K.; HOOS, H.; VISSER, J. Software engineering practices for machine learning – Adoption, effects, and team assessment. The Journal of Systems & Software. 209. 2024. DOI https://doi.org/10.1016/j.jss.2023.111907

STEIDL, M.; FELDERER, M.; RAMLER, R. The pipeline for continuous development of artificial intelligence models – Current state of research and practice. The Journal of Systems & Software. 199. 2023. DOI https://doi.org/10.1016/j.jss.2023.111615

XIN, D.; WU, E. Y.; LEE, D. J.; SALEHI, N.; PARAMESWARAN, A. Whither AutoML? Understanding the Role of Automation in Machine Learning Workflows. In CHI Conference on Human Factors in Computing Systems (CHI'21), Maio 8-13, 2021, Yokohama, Japão. DOI https://doi.org/10.1145/3411764.3445306

2 Orientações adicionais

Escolha o artigo que for mais interessante para você. Utilize tradutores e o Chat GPT para entender o conteúdo dos artigos – caso precise, mas escreva o resumo em língua portuguesa e nas suas palavras.

Não esqueça de preencher, no trabalho, os campos relativos ao seu nome e ao artigo escolhido.

No *template*, você deverá responder às seguintes questões:

- Qual o objetivo do estudo descrito pelo artigo?
- Qual o problema/oportunidade/situação que levou a necessidade de realização deste estudo?
- Qual a metodologia que os autores usaram para obter e analisar as informações do estudo?
- Quais os principais resultados obtidos pelo estudo?

Responda cada questão utilizando o espaço fornecido no *template*, sem alteração do tamanho da fonte (Times New Roman, 10), nem alteração do espaçamento entre linhas (1.0).

Não altere as questões do template.

Utilize o editor de textos de sua preferência para preencher as respostas, mas entregue o trabalho em PDF.

B – RESOLUÇÃO

Questão 1)

Qual o objetivo do estudo descrito pelo artigo?

O artigo tem por objetivo identificar os desafios comuns, as melhores práticas de design e as principais decisões de design de arquitetura de software de sistemas habilitados para aprendizado de máquina do ponto de vista de pesquisadores e profissionais da área. Com o crescimento cada vez mais veloz das necessidades de uso das técnicas de Machine Learning em áreas tais como na de veículos autônomos, robótica e Internet das Coisas, o estudo visa fornecer apoio no enfrentamento destas complexidades e especificidades de modo a melhorar sua eficiência, confiabilidade e capacidade de manutenção e evolução contínua. Os autores baseiam sua pesquisa na revisão da literatura existente e em entrevistas com especialistas da área, com o objetivo de combinar as teorias acadêmicas com as experiências práticas do mercado.

Questão 2)

Qual o problema/oportunidade/situação que levou à necessidade de realização desse estudo?

O estudo foi motivado pela crescente complexidade dos sistemas habilitados para aprendizado de máquina. Por tratar-se de sistemas atuantes em áreas críticas trazem desafios específicos tanto para o design quanto para a arquitetura devido à natureza dos modelos de Machine Learning que frequentemente precisam lidar com grandes quantidades de dados e realizar operações complexas. A necessidade de garantir a confiabilidade e a manutenção desses sistemas altamente sensíveis a alterações exige atualizações constantes para melhorar o desempenho e a precisão dos modelos. Tendo em vista que as abordagens tradicionais de engenharia de software são insuficientes para lidar com este cenário o estudo procura criar uma compreensão estruturada dos desafios identificando ideias que podem ajudar

pesquisadores e profissionais da área no desenvolvimento mais eficaz de sistema habilitados para aprendizado de máquina.

Questão 3)
Qual a metodologia que os autores usaram para obter e analisar as informações do estudo?

Os autores utilizaram uma abordagem mista que combina a revisão sistemática da literatura existente com entrevistas com especialistas. Para revisão sistemática da literatura foram utilizados como base os dados acadêmicos de 3038 estudos relacionados ao tema. A estes estudos foram aplicados critérios de inclusão e exclusão resultando em 41 estudos classificados para maior aprofundamento dos quais foram identificados os desafios, as práticas de design e as decisões de arquitetura. Já as entrevistas com especialistas tiveram por objetivo a validação e complemento dos estudos acadêmicos. Tais entrevistas foram aplicadas a 12 especialistas de 09 países, todos com experiência significativa em desenvolvimento e implementação de sistemas de Machine Learning, resultando em insights práticos sobre os desafios e práticas observados no dia a dia. Os dados obtidos através destas duas abordagens foram comparados, correlacionados e discutidos intra equipe de pesquisa com o objetivo de identificar temas sobrepostos e perspectivas únicas. Foram utilizados métodos quantitativos e qualitativos para analisar os dados coletados o que incluiu técnicas de codificação para categorizar a informação, análise temática para extração de padrões e percepções.

Questão 4)
Quais os principais resultados obtidos pelo estudo?

Como principais resultados obtidos do estudo inclui-se a identificação de desafios, tendo sido identificados 35 desafios, estes agrupados por categorias como arquitetura, dados, evolução, ciclo de vida de desenvolvimento de software, e garantia de qualidade. Os desafios mais significativos incluem a gestão de dependências de dados, a garantia da qualidade e confiabilidade do sistema, o tratamento de complexidades de arquitetura, o apoio à evolução do modelo, e a integração entre sistemas. Um outro resultado obtido foi a relação de melhores práticas, tendo sido identificadas 42 melhores práticas. A adoção de arquiteturas de micro serviços para modularidade, a implementação de mecanismos de tolerância a falhas, a normalização do processo de formação foram alguns dos exemplos de melhores práticas identificadas às quais também foram atribuídas categorias, idênticas as anteriores. O estudo destacou ainda 27 importantes decisões a respeito de

design de arquitetura que consideram a seleção de arquiteturas adequadas, a escolha de plataformas de aprendizado de máquina apropriadas, e a gestão de configurações de pipeline de dados, decisões que têm por objetivo orientar os profissionais na criação de sistemas escaláveis, flexíveis. Em resumo, o estudo fornece uma base estruturada para que pesquisadores e profissionais da área possam apoiar-se ao desenvolver seus sistemas de Machine Learning com destacando a importância de práticas e decisões específicas para lidar com a complexidade e os desafios únicos desses sistemas.

Referência bibliográfica:
https://www.sciencedirect.com/science/article/pii/S0164121223002558?via%3Dihub

APÊNDICE 13 – FRAMEWORKS DE INTELIGÊNCIA ARTIFICIAL

A – ENUNCIADO

1 Classificação (RNA)

Implementar o exemplo de Classificação usando a base de dados Fashion MNIST e a arquitetura RNA vista na aula **FRA - Aula 10 - 2.4 Resolução de exercício de RNA - Classificação**. Além disso, fazer uma breve explicação dos seguintes resultados:

- Gráficos de perda e de acurácia;
- Imagem gerada na seção "**Mostrar algumas classificações erradas**", apresentada na aula prática.

Informações:

- **Base de dados:** Fashion MNIST Dataset
- **Descrição**: Um dataset de imagens de roupas, onde o objetivo é classificar o tipo de vestuário. É semelhante ao famoso dataset MNIST, mas com peças de vestuário em vez de dígitos.
- **Tamanho**: 70.000 amostras, 784 features (28x28 pixels).
- **Importação do dataset**: Copiar código abaixo.

```
data = tf.keras.datasets.fashion_mnist
(x_train, y_train), (x_test, y_test) = fashion_mnist.load_data()
```

2 Regressão (RNA)

Implementar o exemplo de Classificação usando a base de dados Wine Dataset e a arquitetura RNA vista na aula **FRA - Aula 12 - 2.5 Resolução de exercício de RNA - Regressão**. Além disso, fazer uma breve explicação dos seguintes resultados:

- Gráficos de avaliação do modelo (loss);
- Métricas de avaliação do modelo (pelo menos uma entre MAE, MSE, R^2).

Informações:

- **Base de dados:** Wine Quality
- **Descrição**: O objetivo deste dataset prever a qualidade dos vinhos com base em suas características químicas. A variável target (y) neste exemplo será o score de qualidade do vinho, que varia de 0 (pior qualidade) a 10 (melhor qualidade)
- **Tamanho**: 1599 amostras, 12 features.
- **Importação**: Copiar código abaixo.

```
url = "https://archive.ics.uci.edu/ml/machine-learning-databases/wine-quality/winequality-red.csv"
data = pd.read_csv(url, delimiter=';')
```

Dica 1. Para facilitar o trabalho, renomeie o nome das colunas para português, dessa forma:

```
data.columns = [
    'acidez_fixa',            # fixed acidity
    'acidez_volatil',         # volatile acidity
    'acido_citrico',          # citric acid
    'acucar_residual',        # residual sugar
    'cloretos',               # chlorides
    'dioxido_de_enxofre_livre', # free sulfur dioxide
    'dioxido_de_enxofre_total', # total sulfur dioxide
    'densidade',              # density
    'pH',                     # pH
    'sulfatos',               # sulphates
    'alcool',                 # alcohol
    'score_qualidade_vinho'              # quality
]
```

Dica 2. Separe os dados (x e y) de tal forma que a última coluna (índice -1), chamada score_qualidade_vinho, seja a variável target (y)

3 Sistemas de Recomendação

Implementar o exemplo de Sistemas de Recomendação usando a base de dados Base_livos.csv e a arquitetura vista na aula **FRA - Aula 22 - 4.3 Resolução do Exercício de Sistemas de Recomendação**. Além disso, fazer uma breve explicação dos seguintes resultados:

- Gráficos de avaliação do modelo (loss);
- Exemplo de recomendação de livro para determinado Usuário.

Informações:

- **Base de dados:** Base_livros.csv
- **Descrição**: Esse conjunto de dados contém informações sobre avaliações de livros (Notas), nomes de livros (Titulo), ISBN e identificação do usuário (ID_usuario)
- **Importação:** Base de dados disponível no Moodle (UFPR Virtual), chamada Base_livros (formato .csv).

4 Deepdream

Implementar o exemplo de implementação mínima de Deepdream usando uma imagem de um felino - retirada do site Wikipedia - e a arquitetura Deepdream vista na aula **FRA - Aula 23 - Prática Deepdream**. Além disso, fazer uma breve explicação dos seguintes resultados:

- Imagem onírica obtida por *Main Loop*;
- Imagem onírica obtida ao levar o modelo até uma oitava;
- Diferenças entre imagens oníricas obtidas com *Main Loop* e levando o modelo até a oitava.

Informações:

- **Base de dados:** https://commons.wikimedia.org/wiki/File:Felis_catus-cat_on_snow.jpg
- **Importação da imagem**: Copiar código abaixo.

```
url = "https://commons.wikimedia.org/wiki/Special:FilePath/Felis_catus-cat_on_snow.jpg"
```

Dica: Para exibir a imagem utilizando display (display.html) use o link https://commons.wikimedia.org/wiki/File:Felis_catus-cat_on_snow.jpg

B – RESOLUÇÃO

Questão 1)

CLASSIFICAÇÃO

```
# Importação das bibliotecas
import tensorflow as tf
import matplotlib.pyplot as plt
import numpy as np
from mlxtend.plotting import plot_confusion_matrix
from sklearn.metrics import confusion_matrix

# Importação dos dados
(x_train, y_train), (x_test, y_test) =
      tf.keras.datasets.fashion_mnist.load_data()
```

```
Downloading data from https://storage.googleapis.com/tensorflow/tf-keras-datasets/train-labels-idx1-ubyte.gz
29515/29515 ━━━━━━━━━━━━━━━━━━━━ 0s 0us/step
Downloading data from https://storage.googleapis.com/tensorflow/tf-keras-datasets/train-images-idx3-ubyte.gz
26421880/26421880 ━━━━━━━━━━━━━━━━━━━━ 0s 0us/step
Downloading data from https://storage.googleapis.com/tensorflow/tf-keras-datasets/t10k-labels-idx1-ubyte.gz
5148/5148 ━━━━━━━━━━━━━━━━━━━━ 0s 1us/step
Downloading data from https://storage.googleapis.com/tensorflow/tf-keras-datasets/t10k-images-idx3-ubyte.gz
4422102/4422102 ━━━━━━━━━━━━━━━━━━━━ 0s 0us/step
```

```
# Pré processamento dos dados
x_train, x_test = x_train/255.0, x_test/255.0
```

```
# Criando modelo
i = tf.keras.layers.Input(shape=(28, 28))
x = tf.keras.layers.Flatten()(i)
x = tf.keras.layers.Dense(128, activation="relu")(x)
x = tf.keras.layers.Dropout(0.2)(x)
x = tf.keras.layers.Dense(10, activation="softmax")(x)
model = tf.keras.models.Model(i, x)

# Compilando modelo
model.compile(optimizer='adam', loss='sparse_categorical_crossentropy',
              metrics=['accuracy'])

# Treinando o modelo
result = model.fit(x_train, y_train, validation_data=(x_test, y_test),
              epochs=10)
```

```
Epoch 1/10
1875/1875 ━━━━━━━━━━━━━━━━━━━━ 10s 4ms/step - accuracy: 0.7670 - loss: 0.6712 - val_accuracy: 0.8414 - val_loss: 0.4391
Epoch 2/10
1875/1875 ━━━━━━━━━━━━━━━━━━━━ 6s 3ms/step - accuracy: 0.8498 - loss: 0.4162 - val_accuracy: 0.8605 - val_loss: 0.3869
Epoch 3/10
1875/1875 ━━━━━━━━━━━━━━━━━━━━ 9s 3ms/step - accuracy: 0.8635 - loss: 0.3718 - val_accuracy: 0.8615 - val_loss: 0.3849
Epoch 4/10
1875/1875 ━━━━━━━━━━━━━━━━━━━━ 5s 2ms/step - accuracy: 0.8727 - loss: 0.3417 - val_accuracy: 0.8711 - val_loss: 0.3553
Epoch 5/10
1875/1875 ━━━━━━━━━━━━━━━━━━━━ 4s 2ms/step - accuracy: 0.8808 - loss: 0.3289 - val_accuracy: 0.8700 - val_loss: 0.3547
Epoch 6/10
1875/1875 ━━━━━━━━━━━━━━━━━━━━ 3s 2ms/step - accuracy: 0.8830 - loss: 0.3155 - val_accuracy: 0.8734 - val_loss: 0.3533
Epoch 7/10
1875/1875 ━━━━━━━━━━━━━━━━━━━━ 4s 2ms/step - accuracy: 0.8850 - loss: 0.3050 - val_accuracy: 0.8785 - val_loss: 0.3354
Epoch 8/10
1875/1875 ━━━━━━━━━━━━━━━━━━━━ 4s 2ms/step - accuracy: 0.8915 - loss: 0.2959 - val_accuracy: 0.8806 - val_loss: 0.3312
Epoch 9/10
1875/1875 ━━━━━━━━━━━━━━━━━━━━ 5s 2ms/step - accuracy: 0.8919 - loss: 0.2865 - val_accuracy: 0.8700 - val_loss: 0.3556
Epoch 10/10
1875/1875 ━━━━━━━━━━━━━━━━━━━━ 5s 2ms/step - accuracy: 0.8927 - loss: 0.2844 - val_accuracy: 0.8825 - val_loss: 0.3324
```

```
# Avaliando o modelo
# Plotar a função de perda
plt.plot(result.history["loss"], label="loss")
plt.plot(result.history["val_loss"], label="val_loss")
plt.legend()
```

```
<matplotlib.legend.Legend at 0x7d6d211df6a0>
```

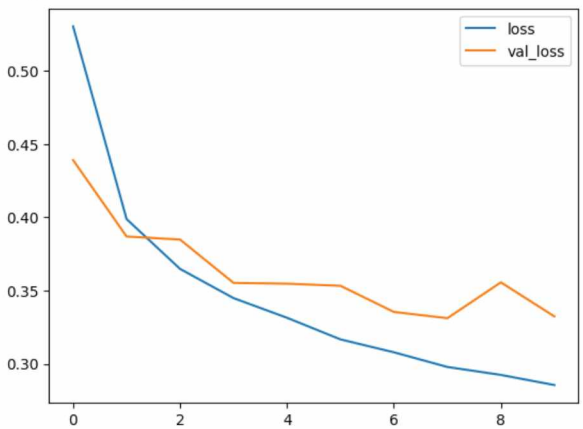

Gráfico de perda

Durante o treinamento do modelo, observamos que, em apenas 10 épocas, houve uma redução significativa na perda do treinamento, que caiu de aproximadamente 0.67 para menos de 0.3. Este resultado é positivo, indicando que o modelo conseguiu aprender a representação dos dados de treinamento de maneira eficiente.

No entanto, a perda de validação não seguiu a mesma tendência de redução esperada, apresentando oscilações ao longo das épocas. Isso pode sugerir a necessidade de mais épocas para observar uma redução mais estável na perda de validação. Alternativamente, se essas oscilações persistirem, pode ser necessário revisar tanto a qualidade e a quantidade dos dados de validação quanto a arquitetura do modelo. Vale destacar que oscilações na perda de validação podem ser indicativas de overfitting, onde o modelo ajusta-se muito bem aos dados de treinamento, mas não generaliza tão bem para dados não vistos

```
# Plotar a acurácia
plt.plot(result.history["accuracy"], label="acc")
plt.plot(result.history["val_accuracy"], label="val_acc")
plt.legend()
```

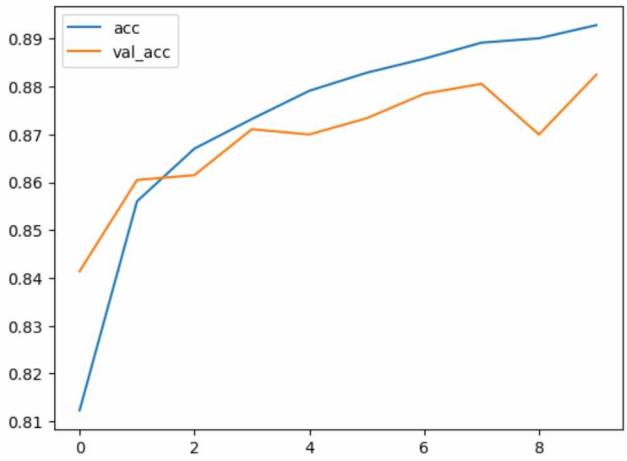

Gráfico de acurácia

Quanto à acurácia, o comportamento observado foi o esperado. A acurácia de treinamento teve um crescimento contínuo, alcançando um valor próximo de 0.9, o que indica que o modelo está aprendendo de forma eficaz. Já a acurácia de validação também cresceu, mas com pequenas flutuações. Embora tenha mantido uma tendência ascendente, essas oscilações podem ser um sinal de que o modelo ainda precisa de mais ajustes para estabilizar a generalização.

```
# Avaliar o modelo com a base de teste
print( model.evaluate(x_test, y_test) )
```

```
313/313 ━━━━━━━━━━━━━━━━━━━━ 0s 1ms/step - accuracy: 0.8804 - loss: 0.3317
[0.3324049711227417, 0.8824999928474426]
```

```
# Predições
y_pred = model.predict(x_test).argmax(axis=1)
print(y_pred)
```

```
313/313 ━━━━━━━━━━━━━━━━━━━━ 1s 2ms/step
[9 2 1 ... 8 1 5]
```

```
# Matriz de confusão
cm = confusion_matrix(y_test, y_pred)
plot_confusion_matrix(conf_mat=cm, figsize=(7, 7),
                      show_normed=True)
```

```
(<Figure size 700x700 with 1 Axes>,
 <Axes: xlabel='predicted label', ylabel='true label'>)
```

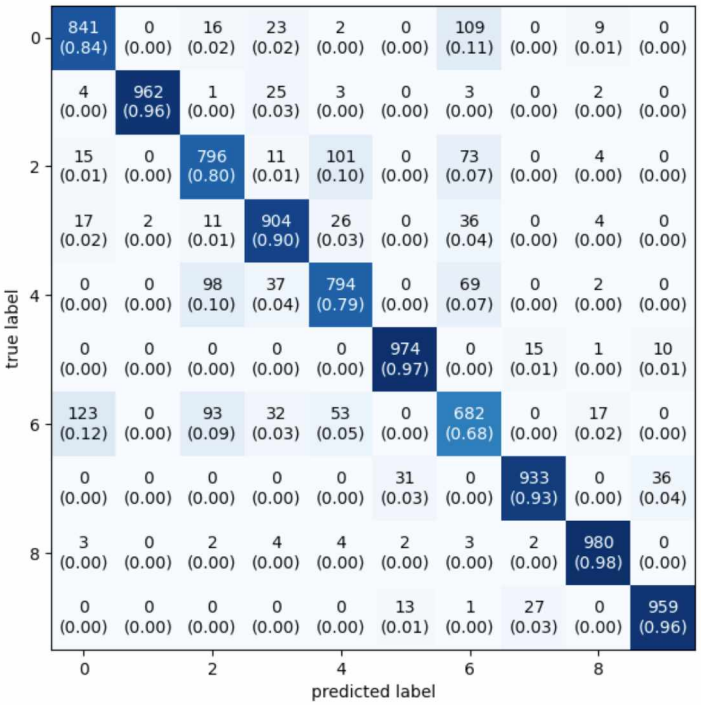


```
# Visualizando classificações erradas
misclassified = np.where(y_pred != y_test)[0]
i = np.random.choice(misclassified)
plt.imshow(x_test[i].reshape(28, 28), cmap="gray")
plt.title("True label: %s Predicted: %s" % (y_test[i], y_pred[i]))
```

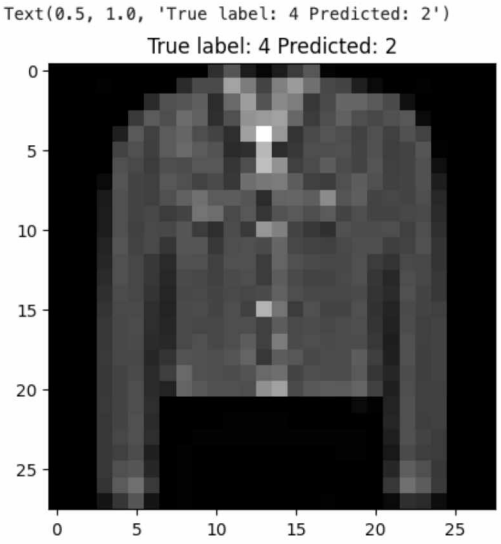

Classificação errada

No exemplo de classificação incorreta, temos uma amostra da categoria 4 que foi erroneamente classificada pelo modelo como categoria 2. Ao analisar a matriz de confusão, observamos que a maior dificuldade do modelo em relação à categoria 4 ocorreu justamente com a categoria 2. Especificamente, o modelo classificou 98 amostras da categoria 4 como pertencentes à categoria 2, resultando na maior taxa de confusão para essa classe.

Questão 2)

REGRESSÃO

```
# Importação de bibliotecas
import tensorflow as tf
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
from sklearn.model_selection import train_test_split
from sklearn.metrics import mean_absolute_error, mean_squared_error, r2_score
from sklearn.preprocessing import StandardScaler

# Importando os dados
url = "https://archive.ics.uci.edu/ml/machine-learning-databases/wine-quality/winequality-red.csv"
data = pd.read_csv(url, delimiter=';')

data.shape
(1599, 12)
```

```
        # Separando em variáveis independentes (X) e dependente (y)
        X = data.drop("quality", axis=1).values
        y = data["quality"].values

        # Pré processamento dos dados
        scaler = StandardScaler()

        X_scaled = scaler.fit_transform(X)

        # Dividir os dados em treino e teste (75% treino, 25% teste)
        X_train,  X_test,  y_train,  y_test  =  train_test_split(X_scaled,
y,random_state=42, test_size=0.25)

        # Criando o modelo
        i = tf.keras.layers.Input(shape=(11,))
        x = tf.keras.layers.Dense(50, activation="relu")(i)
        x = tf.keras.layers.Dense(1)(x)

        model = tf.keras.models.Model(i, x)

        # Compilação
        model.compile(optimizer=tf.keras.optimizers.Adam(learning_rate=0.001
), loss='mse')

        # Early stop para epochs
        early_stop = tf.keras.callbacks.EarlyStopping(
                                    monitor='val_loss',
                                    patience=20,
                                    restore_best_weights=True)

        # Treinar o modelo
        history     =     model.fit(X_train,     y_train,     epochs=1500,
validation_split=0.2,callbacks=[early_stop])
```

```
Epoch 1/1500
30/30 ━━━━━━━━━━━━━━━━━━━━ 3s 32ms/step - loss: 28.6536 - val_loss: 22.9032
Epoch 2/1500
30/30 ━━━━━━━━━━━━━━━━━━━━ 0s 4ms/step - loss: 21.1536 - val_loss: 16.2289
Epoch 3/1500
30/30 ━━━━━━━━━━━━━━━━━━━━ 0s 3ms/step - loss: 14.3322 - val_loss: 10.8584
Epoch 4/1500
30/30 ━━━━━━━━━━━━━━━━━━━━ 0s 4ms/step - loss: 9.6321 - val_loss: 6.9232
Epoch 5/1500
30/30 ━━━━━━━━━━━━━━━━━━━━ 0s 4ms/step - loss: 6.1569 - val_loss: 4.5370
Epoch 6/1500
30/30 ━━━━━━━━━━━━━━━━━━━━ 0s 3ms/step - loss: 4.1051 - val_loss: 3.2617
Epoch 7/1500
30/30 ━━━━━━━━━━━━━━━━━━━━ 0s 4ms/step - loss: 2.9594 - val_loss: 2.6936
Epoch 8/1500
30/30 ━━━━━━━━━━━━━━━━━━━━ 0s 6ms/step - loss: 2.5560 - val_loss: 2.4147
Epoch 9/1500
30/30 ━━━━━━━━━━━━━━━━━━━━ 0s 3ms/step - loss: 2.2935 - val_loss: 2.2617
Epoch 10/1500
30/30 ━━━━━━━━━━━━━━━━━━━━ 0s 4ms/step - loss: 2.1241 - val_loss: 2.1590
Epoch 11/1500
```

```
Epoch 183/1500
30/30 ━━━━━━━━━━━━━━━━━━━━ 0s 3ms/step - loss: 0.3039 - val_loss: 0.3395
Epoch 184/1500
30/30 ━━━━━━━━━━━━━━━━━━━━ 0s 2ms/step - loss: 0.2764 - val_loss: 0.3501
Epoch 185/1500
30/30 ━━━━━━━━━━━━━━━━━━━━ 0s 2ms/step - loss: 0.2795 - val_loss: 0.3444
Epoch 186/1500
30/30 ━━━━━━━━━━━━━━━━━━━━ 0s 2ms/step - loss: 0.2915 - val_loss: 0.3429
Epoch 187/1500
30/30 ━━━━━━━━━━━━━━━━━━━━ 0s 2ms/step - loss: 0.3004 - val_loss: 0.3501
Epoch 188/1500
30/30 ━━━━━━━━━━━━━━━━━━━━ 0s 3ms/step - loss: 0.3002 - val_loss: 0.3481
Epoch 189/1500
30/30 ━━━━━━━━━━━━━━━━━━━━ 0s 4ms/step - loss: 0.3034 - val_loss: 0.3435
Epoch 190/1500
30/30 ━━━━━━━━━━━━━━━━━━━━ 0s 4ms/step - loss: 0.3077 - val_loss: 0.3426
Epoch 191/1500
30/30 ━━━━━━━━━━━━━━━━━━━━ 0s 3ms/step - loss: 0.2900 - val_loss: 0.3439
Epoch 192/1500
30/30 ━━━━━━━━━━━━━━━━━━━━ 0s 4ms/step - loss: 0.2906 - val_loss: 0.3475
```

```
# Plotar os gráficos de loss
plt.figure(figsize=(12, 6))
plt.plot(history.history['loss'], label='Loss (Treinamento)')
plt.plot(history.history['val_loss'], label='Loss (Validação)')
plt.title('Função de Perda Durante o Treinamento')
plt.xlabel('Epochs')
plt.ylabel('Loss')
plt.legend()
plt.show()
```

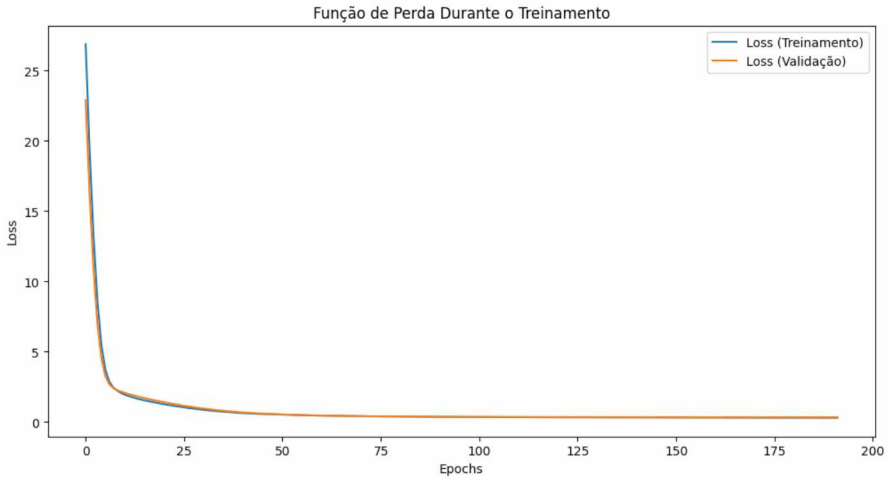

Gráfico de perda

Pelo gráfico de perda, podemos observar que por volta de 40 epochs, o modelo atingiu um valor mínimo de perda, o que implica na não necessidade de continuar treinando o modelo, visto que a perda se tornou estável.

```
# Fazer predições com o conjunto de teste
y_pred = model.predict(X_test).flatten()

# Calcular MAE, MSE e R²
mae = mean_absolute_error(y_test, y_pred)
mse = mean_squared_error(y_test, y_pred)
r2 = r2_score(y_test, y_pred)

# Plotar as métricas
print(f"MAE: {mae}")
print(f"MSE: {mse}")
print(f"R²: {r2}")
```

```
13/13 ━━━━━━━━━━━━━━━━━━━━ 0s 2ms/step
MAE: 0.4805771422386169
MSE: 0.3634197126441913
R²: 0.412506639957428
```

Avaliando as métricas

MAE (0.48): O erro médio absoluto indica que o modelo prevê valores com uma média de erro moderada. Embora não seja muito alto, ainda há espaço para reduzir a diferença entre as previsões e os valores reais.

MSE (0.36): Esse valor reforça que o modelo não comete muitos erros grandes, mas ainda apresenta alguma inconsistência que poderia ser melhorada.

R^2 (0.41): O modelo explica 41% da variação nas classes, indicando uma correlação modesta com as classes reais. Isso sugere que ele ainda não captura totalmente as variações no padrão dos dados.

Em resumo, o modelo possui um desempenho razoável, mas ajustes finos, como aprimoramento no pré-processamento, ajustando as features e a regularização ou experimentação com diferentes configurações, poderiam melhorar os resultados.

Questão 3)

SISTEMA DE RECOMENDAÇÃO

```
# Importação de bibliotecas
import tensorflow as tf
from tensorflow.keras.layers import Input, Dense, Embedding, Flatten,
       Concatenate
from tensorflow.keras.models import Model
from tensorflow.keras.optimizers import SGD, Adam
from sklearn.utils import shuffle
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt

# Leitura dos arquivos
# Antes de executar, importar para o ambiente o arquivo base
data = pd.read_csv('./Base_livros.csv')
data.head()
```

	ISBN	Titulo	Autor	Ano	Editora	ID_usuario	Notas
0	2005018	Clara Callan	Richard Bruce Wright	2001	HarperFlamingo Canada	276725	0
1	60973129	Decision in Normandy	Carlo D'Este	1991	HarperPerennial	276726	2
2	374157065	Flu: The Story of the Great Influenza Pandemic...	Gina Bari Kolata	1999	Farrar Straus Giroux	276727	6
3	393045218	The Mummies of Urumchi	E. J. W. Barber	1999	W. W. Norton & Company	276729	1
4	399135782	The Kitchen God's Wife	Amy Tan	1991	Putnam Pub Group	276729	9

```
data.dtypes
```

	0
ISBN	object
Titulo	object
Autor	object
Ano	int64
Editora	object
ID_usuario	int64
Notas	int64

dtype: object

```
# Converter IDusuario e ISBN em categóricos e criar novos códigos
data.ID_usuario = pd.Categorical(data.ID_usuario)
data['new_user_id'] = data.ID_usuario.cat.codes
```

```
data.ISBN = pd.Categorical(data.ISBN)
data['new_isbn'] = data.ISBN.cat.codes
data.head()
```

	ISBN	Titulo	Autor	Ano	Editora	ID_usuario	Notas	new_user_id	new_isbn
0	2005018	Clara Callan	Richard Bruce Wright	2001	HarperFlamingo Canada	276725	0	11137	26377
1	60973129	Decision in Normandy	Carlo D'Este	1991	HarperPerennial	276726	2	11138	87069
2	374157065	Flu: The Story of the Great Influenza Pandemic...	Gina Bari Kolata	1999	Farrar Straus Giroux	276727	6	11139	50383
3	393045218	The Mummies of Urumchi	E. J. W. Barber	1999	W. W. Norton & Company	276729	1	11140	56644
4	399135782	The Kitchen God's Wife	Amy Tan	1991	Putnam Pub Group	276729	9	11140	59080

```
# Dimensões
N = len(set(data.new_user_id))
M = len(set(data.new_isbn))

user_ids, isbn, ratings = shuffle(data.new_user_id, data.new_isbn,
data.Notas)
Ntrain = int(0.8 * len(ratings)) # separar os dados 80% x 20%
train_user = user_ids[:Ntrain]
train_book = isbn[:Ntrain]
train_ratings = ratings[:Ntrain]
test_user = user_ids[Ntrain:]
test_book = isbn[Ntrain:]
test_ratings = ratings[Ntrain:]

# Centralizar as notas
avg_rating = train_ratings.mean()
train_ratings = train_ratings - avg_rating
test_ratings = test_ratings - avg_rating

# Lista de valores de K para testar
embedding_sizes = [10, 20, 50]

# Dicionário para armazenar os resultados
results = {}

for K in embedding_sizes:
    print(f"\nTreinando modelo com K = {K}")
    # Camada de entrada e embedding para usuários
    u = Input(shape=(1,))
    u_emb = Embedding(N, K)(u)
    u_emb = Flatten()(u_emb)

    # Camada de entrada e embedding para livros
```

```
    m = Input(shape=(1,))
    m_emb = Embedding(M, K)(m)
    m_emb = Flatten()(m_emb)

    # Concatenar embeddings e passar pelas camadas densas
    x = Concatenate()([u_emb, m_emb])
    x = Dense(1024, activation="relu")(x)
    x = Dense(1)(x)

    # Criar o modelo
    model = Model(inputs=[u, m], outputs=x)

    # Compilar o modelo
    model.compile(
        loss="mse",
        optimizer=SGD(learning_rate=0.08, momentum=0.9)
    )

    # Treinamento do modelo
    r = model.fit(
        x=[train_user, train_book],
        y=train_ratings,
        epochs=25,
        batch_size=1024,
        verbose=2,
        validation_data=([test_user, test_book], test_ratings)
    )

    # Salvar histórico de treinamento
    results[K] = {
        "history": r.history,
        "model": model
    }

    # Plotar os gráficos de perda para análise
    plt.plot(r.history["loss"], label=f"train_loss (K={K})")
    plt.plot(r.history["val_loss"], label=f"val_loss (K={K})")

# Mostrar o gráfico consolidado
plt.title("Evolução da Perda para Diferentes Valores de K")
plt.xlabel("Épocas")
```

```
plt.ylabel("Erro Quadrático Médio (MSE)")
plt.legend()
plt.show()

Treinando modelo com K = 10
Epoch 1/25
101/101 - 2s - 22ms/step - loss: 9.9870 - val_loss: 9.9850
Epoch 2/25
101/101 - 1s - 10ms/step - loss: 9.9880 - val_loss: 9.9926
Epoch 3/25
101/101 - 0s - 3ms/step - loss: 9.9878 - val_loss: 9.9994
Epoch 4/25
101/101 - 0s - 3ms/step - loss: 9.9685 - val_loss: 10.0103
Epoch 5/25
101/101 - 0s - 3ms/step - loss: 9.3093 - val_loss: 10.7648
Epoch 6/25
101/101 - 0s - 3ms/step - loss: 1.9306 - val_loss: 11.1163
Epoch 7/25
101/101 - 0s - 3ms/step - loss: 0.3591 - val_loss: 10.6396
Epoch 8/25
101/101 - 0s - 2ms/step - loss: 0.0571 - val_loss: 10.6241
Epoch 9/25
101/101 - 0s - 3ms/step - loss: 0.0125 - val_loss: 10.6101
Epoch 10/25
101/101 - 0s - 3ms/step - loss: 0.0037 - val_loss: 10.6141
Epoch 11/25
101/101 - 0s - 3ms/step - loss: 0.0014 - val_loss: 10.6112
Epoch 12/25
101/101 - 0s - 3ms/step - loss: 6.0859e-04 - val_loss: 10.6120
Epoch 13/25
101/101 - 0s - 3ms/step - loss: 2.8776e-04 - val_loss: 10.6108
Epoch 14/25
101/101 - 1s - 6ms/step - loss: 1.4380e-04 - val_loss: 10.6123
Epoch 15/25
101/101 - 0s - 3ms/step - loss: 7.2827e-05 - val_loss: 10.6120
Epoch 16/25
101/101 - 0s - 3ms/step - loss: 3.6910e-05 - val_loss: 10.6117
Epoch 17/25
101/101 - 1s - 6ms/step - loss: 1.8649e-05 - val_loss: 10.6118
Epoch 18/25
101/101 - 0s - 3ms/step - loss: 9.4559e-06 - val_loss: 10.6119
```

```
Epoch 19/25
101/101 - 0s - 3ms/step - loss: 4.8864e-06 - val_loss: 10.6119
Epoch 20/25
101/101 - 0s - 3ms/step - loss: 2.4205e-06 - val_loss: 10.6118
Epoch 21/25
101/101 - 0s - 3ms/step - loss: 1.2979e-06 - val_loss: 10.6118
Epoch 22/25
101/101 - 0s - 3ms/step - loss: 7.7653e-07 - val_loss: 10.6119
Epoch 23/25
101/101 - 0s - 3ms/step - loss: 4.5746e-07 - val_loss: 10.6119
Epoch 24/25
101/101 - 0s - 2ms/step - loss: 3.7219e-07 - val_loss: 10.6119
Epoch 25/25
101/101 - 0s - 2ms/step - loss: 2.9629e-07 - val_loss: 10.6119

Treinando modelo com K = 20
Epoch 1/25
101/101 - 2s - 23ms/step - loss: 9.9893 - val_loss: 10.0220
Epoch 2/25
101/101 - 1s - 10ms/step - loss: 9.9903 - val_loss: 9.9911
Epoch 3/25
101/101 - 0s - 3ms/step - loss: 9.9631 - val_loss: 10.0077
Epoch 4/25
101/101 - 0s - 3ms/step - loss: 9.4633 - val_loss: 10.6271
Epoch 5/25
101/101 - 0s - 3ms/step - loss: 2.1928 - val_loss: 11.1953
Epoch 6/25
101/101 - 0s - 3ms/step - loss: 0.5357 - val_loss: 10.5957
Epoch 7/25
101/101 - 0s - 3ms/step - loss: 0.0845 - val_loss: 10.5507
Epoch 8/25
101/101 - 0s - 2ms/step - loss: 0.0200 - val_loss: 10.5499
Epoch 9/25
101/101 - 0s - 3ms/step - loss: 0.0067 - val_loss: 10.5403
Epoch 10/25
101/101 - 0s - 3ms/step - loss: 0.0027 - val_loss: 10.5397
Epoch 11/25
101/101 - 0s - 3ms/step - loss: 0.0013 - val_loss: 10.5393
Epoch 12/25
101/101 - 0s - 3ms/step - loss: 6.8140e-04 - val_loss: 10.5381
Epoch 13/25
```

```
101/101 - 0s - 3ms/step - loss: 3.7453e-04 - val_loss: 10.5378
Epoch 14/25
101/101 - 0s - 3ms/step - loss: 2.1258e-04 - val_loss: 10.5379
Epoch 15/25
101/101 - 0s - 3ms/step - loss: 1.2302e-04 - val_loss: 10.5380
Epoch 16/25
101/101 - 0s - 3ms/step - loss: 7.0752e-05 - val_loss: 10.5380
Epoch 17/25
101/101 - 0s - 3ms/step - loss: 3.9592e-05 - val_loss: 10.5375
Epoch 18/25
101/101 - 1s - 6ms/step - loss: 2.2476e-05 - val_loss: 10.5376
Epoch 19/25
101/101 - 1s - 6ms/step - loss: 1.2828e-05 - val_loss: 10.5377
Epoch 20/25
101/101 - 1s - 6ms/step - loss: 7.4559e-06 - val_loss: 10.5377
Epoch 21/25
101/101 - 0s - 3ms/step - loss: 4.2742e-06 - val_loss: 10.5377
Epoch 22/25
101/101 - 0s - 3ms/step - loss: 2.4040e-06 - val_loss: 10.5377
Epoch 23/25
101/101 - 0s - 3ms/step - loss: 1.3768e-06 - val_loss: 10.5377
Epoch 24/25
101/101 - 0s - 3ms/step - loss: 8.0975e-07 - val_loss: 10.5377
Epoch 25/25
101/101 - 0s - 3ms/step - loss: 4.7374e-07 - val_loss: 10.5377

Treinando modelo com K = 50
Epoch 1/25
101/101 - 2s - 24ms/step - loss: 9.9945 - val_loss: 9.9876
Epoch 2/25
101/101 - 1s - 10ms/step - loss: 9.9811 - val_loss: 9.9865
Epoch 3/25
101/101 - 0s - 3ms/step - loss: 9.9909 - val_loss: 10.0288
Epoch 4/25
101/101 - 0s - 3ms/step - loss: 9.7871 - val_loss: 10.2950
Epoch 5/25
101/101 - 0s - 3ms/step - loss: 10.5080 - val_loss: 11.0647
Epoch 6/25
101/101 - 0s - 3ms/step - loss: 5.1707 - val_loss: 10.7645
Epoch 7/25
101/101 - 0s - 3ms/step - loss: 1.1846 - val_loss: 10.5256
```

```
Epoch 8/25
101/101 - 0s - 3ms/step - loss: 0.3747 - val_loss: 10.4614
Epoch 9/25
101/101 - 1s - 6ms/step - loss: 0.1778 - val_loss: 10.4936
Epoch 10/25
101/101 - 0s - 3ms/step - loss: 0.1158 - val_loss: 10.4628
Epoch 11/25
101/101 - 0s - 3ms/step - loss: 0.0866 - val_loss: 10.4564
Epoch 12/25
101/101 - 0s - 3ms/step - loss: 0.0641 - val_loss: 10.4712
Epoch 13/25
101/101 - 1s - 6ms/step - loss: 0.0452 - val_loss: 10.4582
Epoch 14/25
101/101 - 0s - 3ms/step - loss: 0.0304 - val_loss: 10.4679
Epoch 15/25
101/101 - 0s - 3ms/step - loss: 0.0166 - val_loss: 10.4700
Epoch 16/25
101/101 - 0s - 3ms/step - loss: 0.0071 - val_loss: 10.4616
Epoch 17/25
101/101 - 0s - 4ms/step - loss: 0.0034 - val_loss: 10.4633
Epoch 18/25
101/101 - 1s - 6ms/step - loss: 0.0017 - val_loss: 10.4591
Epoch 19/25
101/101 - 0s - 4ms/step - loss: 0.0011 - val_loss: 10.4602
Epoch 20/25
101/101 - 0s - 4ms/step - loss: 6.6750e-04 - val_loss: 10.4609
Epoch 21/25
101/101 - 0s - 4ms/step - loss: 4.2016e-04 - val_loss: 10.4601
Epoch 22/25
101/101 - 1s - 6ms/step - loss: 2.9959e-04 - val_loss: 10.4607
Epoch 23/25
101/101 - 1s - 6ms/step - loss: 2.3958e-04 - val_loss: 10.4604
Epoch 24/25
101/101 - 0s - 3ms/step - loss: 1.9933e-04 - val_loss: 10.4605
Epoch 25/25
101/101 - 0s - 3ms/step - loss: 1.5061e-04 - val_loss: 10.4605
```

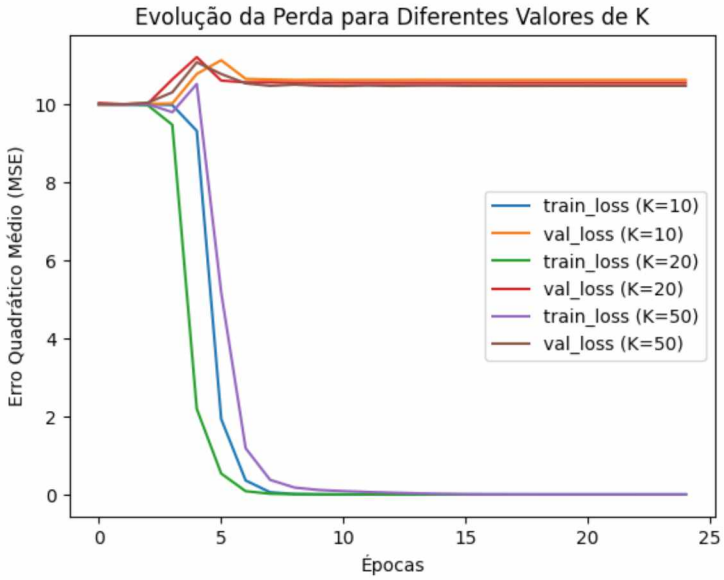

Avaliação função de perda

Os resultados obtidos indicam que o modelo apresenta sobreajuste, com a perda de treinamento diminuindo significativamente, mas a perda de validação permanecendo estável em torno de 10,5. Isso sugere que o modelo está ajustando bem os dados de treinamento, mas não consegue generalizar para o conjunto de validação. Além disso, não houve melhorias significativas na perda de validação ao testar diferentes valores para K. Logo, é necessário reavaliar o modelo, modificar sua arquitetura, testar diferentes funções de perda e avaliar a qualidade e representatividade dos dados para melhorar o desempenho.

```
# Nova recomendação
# Gerar o array com o usuário único
# Repete a quantidade de livros
books = np.array(list(set(isbn)))
input_usuario = np.repeat(a=6636, repeats=M)
preds = model.predict( [input_usuario, books] )

# Descentraliza as predições
rat = preds.flatten() + avg_rating

# Índice da maior nota
idx = np.argmax(rat)
print("Recomendação: Livro - ", books[idx], " / ", rat[idx] , "*")
```

```
4028/4028 ━━━━━━━━━━━━━━━━━━━━ 6s 1ms/step
Recomendação: Livro -  109231  /  10.528166 *
```

Avaliação da recomendação

O modelo recomendou que o usuário com ID 6636 daria nota de aproximadamente 10 para o livro com ISBN 109231.

Questão 4)

DEEPDREAM

```
# Importação das bibliotecas
import tensorflow as tf
import numpy as np
import matplotlib.pyplot as plt
import IPython.display as display
import PIL.Image

# Importação da imagem
url = 'https://upload.wikimedia.org/wikipedia/commons/b/b6/Felis_catus-
cat_on_snow.jpg'

# Download da imagem e gravação em array Numpy
def download(url, max_dim=None):
  name = url.split('/')[-1]
  image_path = tf.keras.utils.get_file(name, origin=url)
  img = PIL.Image.open(image_path)
  if max_dim:
    img.thumbnail((max_dim, max_dim))
  return np.array(img)

# Normalização da imagem
def deprocess(img):
  img = 255*(img + 1.0)/2.0
  return tf.cast(img, tf.uint8)

# Exibir a imagem
def show(img):
  display.display(PIL.Image.fromarray(np.array(img)))

# Leitura da Imagem
original_img = download(url, max_dim=500)
show(original_img)
display.display(display.HTML('<a
"href=https://commons.wikimedia.org/wiki/File:Felis_catus-
cat_on_snow.jpg"/>'))
```

```
Preparando modelo de classificação
base_model = tf.keras.applications.InceptionV3(include_top=False,
      weights='imagenet')
```

```
Downloading data from https://storage.googleapis.com/tensorflow/keras-applications/inception_v3/inception_v3_weights_tf_dim_ordering_tf_kernels_notop.h5
87910968/87910968 ━━━━━━━━━━━━━━━━━━━━ 1s 0us/step
```

```
# Selecionando as camadas da rede para maximizar a perda
names = ['mixed3', 'mixed5']
layers = [base_model.get_layer(name).output for name in names]

# Criação do modelo dream
dream_model = tf.keras.Model(inputs=base_model.input, outputs=layers)

# Função para calcular a perda
def calc_loss(img, model):
  img_batch = tf.expand_dims(img, axis=0)
  layer_activations = model(img_batch)
  if len(layer_activations) == 1:
    layer_activations = [layer_activations]
  losses = []
  for act in layer_activations:
    loss = tf.math.reduce_mean(act)
    losses.append(loss)
  return  tf.reduce_sum(losses)

# DeepDream
class DeepDream(tf.Module):
  def __init__(self, model):
    self.model = model
  @tf.function(
      input_signature=(
        tf.TensorSpec(shape=[None,None,3], dtype=tf.float32),
```

```
        tf.TensorSpec(shape=[], dtype=tf.int32),
        tf.TensorSpec(shape=[], dtype=tf.float32),)
  )
  def __call__(self, img, steps, step_size):
      print("Tracing")
      loss = tf.constant(0.0)
      for n in tf.range(steps):
        with tf.GradientTape() as tape:
          tape.watch(img)
          loss = calc_loss(img, self.model)
        gradients = tape.gradient(loss, img)
        gradients /= tf.math.reduce_std(gradients) + 1e-8
        img = img + gradients*step_size
        img = tf.clip_by_value(img, -1, 1)
      return loss, img
deepdream = DeepDream(dream_model)

# Main Loop
def run_deep_dream_simple(img, steps=100, step_size=0.01):
  img = tf.keras.applications.inception_v3.preprocess_input(img)
  img = tf.convert_to_tensor(img)
  step_size = tf.convert_to_tensor(step_size)
  steps_remaining = steps
  step = 0
  while steps_remaining:
    if steps_remaining>100:
      run_steps = tf.constant(100)
    else:
      run_steps = tf.constant(steps_remaining)
    steps_remaining -= run_steps
    step += run_steps
    loss, img = deepdream(img, run_steps, tf.constant(step_size))
    display.clear_output(wait=True)
    show(deprocess(img))
    print ("Step {}, loss {}".format(step, loss))
  result = deprocess(img)
  display.clear_output(wait=True)
  show(result)
  return result

# Aplicando Main Loop
```

```
dream_img = run_deep_dream_simple(img=original_img,
                                  steps=100, step_size=0.01)
```

Explicação resultado Main Loop

A imagem onírica obtida após o Main Loop representa uma visão alucinada e distorcida da imagem original. Apesar da baixa resolução, podemos observar que alguns padrões detectados pela rede neural foram ampliados, contudo esses padrões não parecem ser tão distintos entre si.

```
# Levando modelo até uma oitava
import time
start = time.time()
OCTAVE_SCALE = 1.30
img = tf.constant(np.array(original_img))
base_shape = tf.shape(img)[:-1]
float_base_shape = tf.cast(base_shape, tf.float32)
for n in range(-2, 3):
  new_shape = tf.cast(float_base_shape*(OCTAVE_SCALE**n), tf.int32)
  img = tf.image.resize(img, new_shape).numpy()
  img = run_deep_dream_simple(img=img, steps=50, step_size=0.01)
display.clear_output(wait=True)
img = tf.image.resize(img, base_shape)
img = tf.image.convert_image_dtype(img/255.0, dtype=tf.uint8)
show(img)
end = time.time()
end-start
```

5.43707537651062

Explicação da imagem obtida com oitava

A imagem obtida da aplicação da técnica das oitavas apresenta uma aparência mais complexa e detalhada com relação aos padrões aprendidos pela rede neural. Isso ocorre pois a imagem é passada pela rede em diferentes escalas de tamanho.

Explicação das diferenças entre imagens oníricas obtidas com Main Loop e levando o modelo até a oitava.

A principal diferença entre as imagens está na complexidade e diversidade dos padrões resultados conforme a técnica aplicada:

- Com o Main Loop, a imagem onírica é uma visão distorcida da original, onde os padrões detectados são ampliados, mas de maneira uniforme e em baixa resolução, resultando em detalhes pouco distintos e uma aparência menos rica.
- Já com a técnica das oitavas, a imagem passa por diferentes escalas de tamanho, o que cria uma composição mais detalhada e complexa. Assim, os padrões surgem em várias granularidades, desde texturas finas até formas maiores, dando profundidade e diversidade à imagem final.

APÊNDICE 14 – VISUALIZAÇÃO DE DADOS E STORYTELLING

A – ENUNCIADO

Escolha um conjunto de dados brutos (ou uma visualização de dados que você acredite que possa ser melhorada) e faça uma visualização desses dados (de acordo com os dados escolhidos e com a ferramenta de sua escolha)

Desenvolva uma narrativa/storytelling para essa visualização de dados considerando os conceitos e informações que foram discutidas nesta disciplina. Não esqueça de deixar claro para seu possível público alvo qual **o objetivo dessa visualização de dados, o que esses dados significam, quais possíveis ações podem ser feitas com base neles.**

Entregue em um PDF:

- O **conjunto de dados brutos** (**ou uma visualização de dados** que você acredite que possa ser **melhorada**);

- Explicação do **contexto e o publico-alvo** da visualização de dados e do storytelling que será desenvolvido;

- A **visualização desses dados** (de acordo com os dados escolhidos e com a ferramenta de sua escolha) **explicando a escolha do tipo de visualização e da ferramenta usada**; (**50 pontos**)

B – RESOLUÇÃO

1. O Conjunto de Dados Brutos

Para desenvolvimento deste trabalho foi utilizada uma matéria jornalística elaborada e publicada pela assessoria de comunicação do Ministério Público do Paraná em 03 de outubro de 2024, sendo esta reproduzida em sua íntegra, abaixo:

"Operação no Paraná identifica 1,4 mil hectares de desmatamento e aplica R$ 13 milhões em multas. A edição de 2024 da Operação Mata Atlântica em Pé foi encerrada na última sexta-feira, 27 de setembro, no Paraná e em outros 16 estados brasileiros em que a força-tarefa foi realizada. No estado, durante duas semanas de fiscalizações – o início foi no dia 16 de setembro – foram vistoriados 405 polígonos e identificados 1.433,33 hectares de área ilegalmente desmatada. A partir da ação, os órgãos ambientais aplicaram, até agora, um total de R$ 13.100.500,00 em multas administrativas aos responsáveis pelos ilícitos ambientais.

Em sua sétima edição nacional a força-tarefa que é coordenada localmente pelos Ministérios Públicos e executada pelos órgãos ambientais, foi iniciada pelo MP do Paraná e tornou-se a maior ação de fiscalização conjunta para o combate ao desmatamento do bioma Mata Atlântica em todo o país.

Cumprimento – No Paraná, a execução da operação fica a cargo dos três órgãos ambientais que atuam no estado, o Instituto Água e Terra (IAT), o Batalhão de Polícia Ambiental Força Verde e a Superintendência do Paraná do Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis (Ibama). A ação no estado neste ano deu enfoque à fiscalização do cumprimento de embargo das áreas já autuadas em edições anteriores da Operação. O objetivo foi verificar se as mesmas estão sendo destinadas à recuperação de vegetação, conforme prevê a legislação.

Tecnologia – Do total das áreas fiscalizadas, 776,52 hectares desmatados foram identificados pelo Instituto Água e Terra a partir do uso de tecnologias de georreferenciamento e monitoramento via imagens de satélite. A fiscalização remota resultou na lavratura de 115 autos de infração, o que gerou a aplicação de R$ 6.621.500,00 em multas pelas infrações administrativas praticadas. O emprego dessas novas tecnologias de monitoramento por satélite – um aprimoramento da operação ao longo dos anos – tem permitido que várias etapas do trabalho, incluindo a elaboração de laudos georreferenciados e a lavratura de autos de infração e termos de embargo, sejam feitas sem a necessidade de visitas ao local do ilícito. Além disso, com a utilização dos dados do Cadastro Ambiental Rural (CAR), são identificados os proprietários das áreas onde há o desmatamento ilegal. Em locais onde não são obtidos, pelas imagens de satélite, elementos suficientes sobre os danos ambientais causados, são realizadas visitas das equipes de fiscalização.

Responsabilização – A atuação integrada dos órgãos ambientais garante ainda a devida responsabilização dos infratores. Uma vez constatados os ilícitos ambientais, os responsáveis são autuados e podem responder judicialmente – nas esferas cível e criminal – além de serem impostas restrições administrativas relacionadas aos registros das propriedades rurais.

Dados nacionais – De acordo com o Ministério Público de Minas Gerais e a Associação Brasileira dos Membros do Ministério Público de Meio Ambiente (Abrampa), que neste ano coordenaram nacionalmente a ação, somando todos os estados participantes, foram constatados 17.124 hectares com supressão ilegal de vegetação nativa e o montante em multas aplicadas foi de R$ 137.515.308,05. A ação também conta com o apoio da Fundação SOS Mata Atlântica e da plataforma

MapBiomas, rede colaborativa que monitora o uso da terra e a cobertura de vegetação, disponibilizando dados de alertas de desmatamento para acesso público (alerta.mapbiomas.org). Neste ano, assim como nas edições anteriores, participaram todos os 17 estados cobertos pelo bioma Mata Atlântica: além do Paraná, os estados de Alagoas, Bahia, Ceará, Espírito Santo, Goiás, Mato Grosso do Sul, Minas Gerais, Paraíba, Pernambuco, Piauí, Rio de Janeiro, Rio Grande do Norte, Rio Grande do Sul, Santa Catarina, São Paulo e Sergipe."

Fonte: https://mppr.mp.br/Noticia/Operacao-no-Parana-identifica-14-mil-hectares-dedesmatamento-e-aplica-R-13-milhoes-em

A partir da matéria acima elaborou-se a seguinte tabela para melhor tratamento dos dados:

Categoria	Informação
Nome da Operação	Operação Mata Atlântica em Pé 2024
Período de Fiscalização	16 a 27 de setembro de 2024
Estados participantes	17 estados brasileiros
Área fiscalizada (PR)	405 polígonos
Área desmatada identificada (PR)	1.433,33 hectares
Área desmatada identificada por satélite (PR)	776,52 hectares
Área desmatada nacionalmente	17.124 hectares
Autos de infração emitidos (PR)	115 autos
Multas aplicadas (PR)	R$ 13.100.500,00
Multas aplicadas nacionalmente	R$ 137.515.308,05
Multas aplicadas por monitoramento remoto (PR)	R$ 6.621.500,00
Foco da operação (PR)	Fiscalização do cumprimento de embargos de áreas autuadas em anos anteriores
Responsáveis pela Operação (PR)	IAT, Batalhão de Polícia Ambiental Força Verde e Ibama
Tecnologias utilizadas	Georreferenciamento e imagens de satélite
Instituições coordenadoras	Ministério Público de MG, Abrampa
Apoios	Fundação SOS Mata Atlântica, MapBiomas

2. Contexto e Público-Alvo

Tomando como fator de motivação os efeitos das recentes ondas de calor, tais como inundações em bairros e municípios diversos e temperaturas e sensação térmica elevadas, que acometem as populações da região de Curitiba e litoral paranaense – ainda que esperados para esta época do ano (primeiro bimestre de 2025), optou-se por utilizar para desenvolvimento deste trabalho um tema relacionado ao desmatamento da Mata Atlântica.

A matéria original informa dos resultados alcançados pela força tarefa coordenada pelo Ministério Público do Paraná e que envolve ainda outros três órgãos fiscalizadores – IAT, Batalhão de Polícia Ambiental Força Verde, e IBAMA, durante o exercício da operação Mata Atlântica em Pé 2024.

Neste contexto, o storytelling disponibilizado mais adiante neste trabalho apresenta ao público em geral, mantendo o público-alvo da matéria original, utilizando-se de recursos visuais, preservando como base o conteúdo escrito originalmente. Com isso, espera-se maior engajamento/interesse do público em relação a importância do tema e das ações desempenhadas pelos órgãos citados.

3. Visualização dos Dados

A nova visualização de dados sugerida foi elaborada mantendo o padrão jornalístico original adicionando recursos visuais para auxílio no entendimento. Os dados foram tratados e gráficos foram gerados utilizando o software Microsoft Excel. O layout do documento foi elaborado utilizando a plataforma Canva.com. A nova disponibilização está disponível no Anexo I deste trabalho.

4. Descrição da Narrativa Storytelling

Para criação da nova visualização utilizou-se a estrutura tradicional de storytelling com introdução – apresentando o cenário geral em relação aos desafios de preservação da Mata Atlântica e de sua fiscalização, apresentação de dados – indicando os dados principais em relação aos resultados obtidos, enredo – enfatizando a importância da tecnologia como aliado na fiscalização, clímax – evidenciando as consequências aos infratores, bem como penalidades a que estão sujeitos em especial pelo uso das tecnologias na fiscalização, e conclusão – reforçando a importância da participação de todo a sociedade como complemento aos esforços dos órgãos governamentais.

Operação Mata Atlântica em Pé 2024

Um Bioma Ameaçado

A Mata Atlântica, um dos ecossistemas mais ricos e ameaçados do Brasil, continua a enfrentar desafios críticos para sua preservação. Apesar de sua importância ecológica e dos esforços de conservação, o desmatamento ilegal avança, destruindo áreas essenciais para a biodiversidade e recursos naturais. Para combate a essa ameaça, a Operação Mata Atlântica em Pé 2024 mobilizou uma força-tarefa em 17 estados brasileiros, promovendo uma ação coordenada para identificar infrações ambientais e punir responsáveis.

Fonte: https://www.aen.pr.gov.br/Noticia/Tecnologia-contra-desmatamento-IAT-fiscaliza-areas-com-corte-de-floresta-remotamente

O desmatamento pode parecer um problema distante, mas suas consequências são diretas: redução da biodiversidade, impacto nos recursos hídricos e intensificação das mudanças climáticas. Cada árvore derrubada ilegalmente compromete um futuro sustentável, tornando a fiscalização uma ferramenta essencial na luta pela preservação do bioma.

A Realidade do Desmatamento

Em sua sétima edição nacional a força-tarefa que é coordenada localmente pelos Ministérios Públicos e executada pelos órgãos ambientais, foi iniciada pelo Ministério Público do Paraná e tornou-se a maior ação de fiscalização conjunta para o combate ao desmatamento do bioma Mata Atlântica em todo o país. No Paraná, a execução da operação fica a cargo dos três órgãos ambientais que atuam no estado, o Instituto Água e Terra (IAT), o Batalhão de Polícia Ambiental Força Verde e o Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis (Ibama). A ação também conta com o apoio da Fundação SOS Mata Atlântica e da plataforma MapBiomas, rede colaborativa que monitora o uso da terra e a cobertura de vegetação, disponibilizando dados de alertas de desmatamento para acesso público.

A edição de 2024 da Operação trouxe números preocupantes. Considerando todos os 17 estados brasileiros participantes da força-tarefa e que suportam o bioma Mata Atlântica, foram identificados 17.124 hectares de área desmatada ilegalmente, resultando na aplicação de R$ 137.515.308,05 em multas aos infratores. Somente no Paraná, houve a identificação de 1.433 hectares de desmatamento ilegal tendo sido aplicadas até o momento o total de R$ 13.100.500,00 em multas administrativas:

O Avanço da Fiscalização e a Reação dos Infratores

Os dados refletem não apenas a escala do problema, mas também os avanços tecnológicos utilizados na fiscalização. No Paraná, o uso de tecnologias permitiu a identificação remota de 776,52 hectares irregularidades resultando na aplicação de R$ 6.621.500,00 em multas, permitindo maior eficiência das autuações e reduzindo a necessidade de deslocamentos de equipes aos locais de infração:

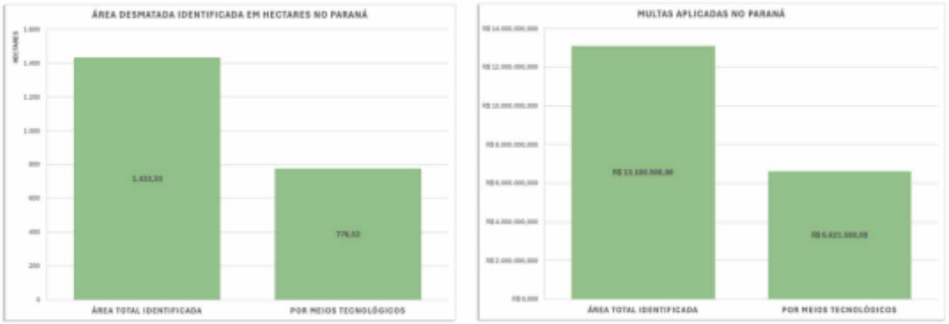

Ainda no Paraná, as equipes concentraram esforços nas áreas já autuadas anteriormente com o objetivo de garantir que estas propriedades estivessem cumprindo as exigências de recuperação da vegetação. No entanto, a realidade em campo revelou que muitas áreas ainda estavam sendo exploradas, resultando em novas autuações e sanções severas.

Resultados obtidos com o uso de tecnologias, como o de imagens de satélite e sistemas de georreferenciamento para cruzamento de dados e identificação dos responsáveis, tornam estes recursos aliados imprescindíveis no monitoramento e aplicação das leis existentes:

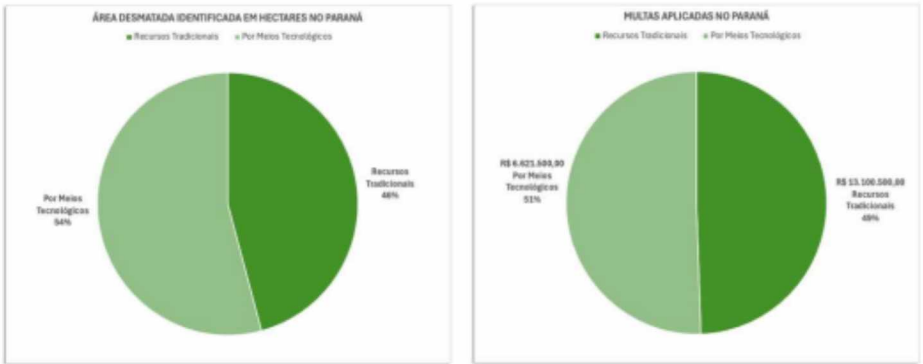

O Cerco Contra o Desmatamento

Os infratores que antes contavam com a dificuldade de monitoramento agora enfrentam um novo cenário. A Operação Mata Atlântica em Pé não se limita apenas à aplicação de multas – os responsáveis pelo desmatamento ilegal podem responder judicialmente nas esferas cível e criminal. Além disso, sanções administrativas restringem o uso das propriedades, impedindo sua regularização até que a recuperação ambiental seja comprovada.

A ação integrada dos Ministérios Públicos, Ibama e órgãos ambientais estaduais tem garantido que quem desmata ilegalmente seja identificado e responsabilizado. O avanço tecnológico combinado à fiscalização presencial torna cada vez mais difícil a continuidade dessas práticas sem consequências.

O Futuro da Mata Atlântica Está em Nossas Mãos

A Operação Mata Atlântica em Pé representa um avanço significativo na fiscalização ambiental no Brasil. No entanto, a luta contra o desmatamento não pode depender exclusivamente das ações governamentais. A sociedade tem um papel fundamental na proteção do meio ambiente:

- Denunciar atividades ilegais é uma forma de contribuir para a preservação;
- Cobrar políticas públicas mais eficazes fortalece o combate ao desmatamento;
- Apoiar projetos de recuperação ambiental ajuda a restaurar áreas degradadas.

A Mata Atlântica ainda resiste, mas cada hectare perdido compromete o equilíbrio ecológico do país. O combate ao desmatamento precisa ser uma prioridade contínua para garantir um futuro sustentável para as próximas gerações.

Fonte:
https://mppr.mp.br/Noticia/Operacao-no-Parana-identifica-14-mil-hectares-de-desmatamento-e-aplica-R-13-milhoes-em

APÊNDICE 15 – TÓPICOS EM INTELIGÊNCIA ARTIFICIAL

A – ENUNCIADO

1) Algoritmo Genético

Problema do Caixeiro Viajante

A Solução poderá ser apresentada em: Python (preferencialmente), ou em R, ou em Matlab, ou em C ou em Java.

Considere o seguinte problema de otimização (a escolha do número de 100 cidades foi feita simplesmente para tornar o problema intratável. A solução ótima para este problema não é conhecida).

Suponha que um caixeiro deva partir de sua cidade, visitar clientes em outras 99 cidades diferentes, e então retornar à sua cidade. Dadas as coordenadas das 100 cidades, descubra o percurso de menor distância que passe uma única vez por todas as cidades e retorne à cidade de origem.

Para tornar a coisa mais interessante, as coordenadas das cidades deverão ser sorteadas (aleatórias), considere que cada cidade possui um par de coordenadas (x e y) em um espaço limitado de 100 por 100 pixels.

O relatório deverá conter no mínimo a primeira melhor solução (obtida aleatoriamente na geração da população inicial) e a melhor solução obtida após um número mínimo de 1000 gerações. Gere as imagens em 2d dos pontos (cidades) e do caminho.

Sugestão:

(1) considere o cromossomo formado pelas cidades, onde a cidade de início (escolhida aleatoriamente) deverá estar na posição 0 e 100 e a ordem das cidades visitadas nas posições de 1 a 99 deverão ser definidas pelo algoritmo genético.
(2) A função de avaliação deverá minimizar a distância euclidiana entre as cidades (os pontos).
(3) Utilize no mínimo uma população com 100 indivíduos;
(4) Utilize no mínimo 1% de novos indivíduos obtidos pelo operador de mutação;
(5) Utilize no mínimo de 90% de novos indivíduos obtidos pelo método de cruzamento (crossover-ox);
(6) Preserve sempre a melhor solução de uma geração para outra.

Importante: A solução deverá implementar os operadores de “cruzamento” e “mutação”.

2) Compare a representação de dois modelos vetoriais

Pegue um texto relativamente pequeno, o objetivo será visualizar a representação vetorial, que poderá ser um vetor por palavra ou por sentença. Seja qual for a situação, considere a quantidade de

palavras ou sentenças onde tenha no mínimo duas similares e no mínimo 6 textos, que deverão produzir no mínimo 6 vetores. Também limite o número máximo, para que a visualização fique clara e objetiva.

O trabalho consiste em pegar os fragmentos de texto e codificá-las na forma vetorial. Após obter os vetores, imprima-os em figuras (plot) que demonstrem a projeção desses vetores usando a PCA.

O PDF deverá conter o código-fonte e as imagens obtidas.

B – RESOLUÇÃO

1. ALGORITMO GENÉTICO

Caixeiro Viajante

```
# Bibliotecas
import matplotlib.pyplot as plt
import numpy as np
import random

# Constantes
# Número de cidades
QUANTIDADE_CIDADES = 100
# Número de indivíduos
QUANTIDADE_INDIVIDUOS = 100
# Referência para dimensão plano cartesiano
TAMANHO_ESPACO = 100
# Taxa mutação
TAXA_MUTACAO = 0.01
# Taxa cruzamento
TAXA_CRUZAMENTO = 0.9
# Número de gerações
QUANTIDADE_GERACOES = 1000

# Função para gerar cidades aleatórias
def gerar_cidades():
cidades = []
for _ in range(QUANTIDADE_CIDADES):
      x_coord, y_coord = random.randint(0,TAMANHO_ESPACO),random.
            randint(0,TAMANHO_ESPACO)
      cidades.append((x_coord, y_coord))
```

```
# Adiciona cidade inicial ao fim
cidades.append(cidades[0])
return cidades

# Função para gerar população inicial
def gerar_populacao_inicial(cidades):
      indices = list(range(len(cidades)))
      populacao = []
      for _ in range(QUANTIDADE_INDIVIDUOS):
            # Gera individuo com caminho aleatório
            individuo = random.sample(indices[1:QUANTIDADE_CIDADES],
                  k=QUANTIDADE_CIDADES-1)
            # Insere cidade inicial/final no individuo
            individuo.insert(0, 0)
            individuo.append(100)
            populacao.append(individuo)
      return populacao

# Função para calcular a distância euclidiana entre as cidades
# d = √((x2 - x1)² + (y2 - y1)²
def calc_distancia_euclidiana(x1, y1, x2, y2) -> float:
      distancia = ((x2 - x1) **2 + (y2 - y1) ** 2) ** 0.5
      return distancia

# Função de avaliação
def calc_custo(caminho, cidades):
      custo = 0
      for i in range(len(caminho) - 1):
            x1, y1 = cidades[caminho[i]]
            x2, y2 = cidades[caminho[i+1]]
            custo += calc_distancia_euclidiana(x1, y1, x2, y2)
      return custo

# Função para realizar seleção por torneio
def selecionar_pais_torneio(populacao, cidades, k= 5):
      escolhidos = random.sample(populacao, k)
      escolhidos.sort(key=lambda x: calc_custo(x, cidades))
      return escolhidos[0], escolhidos[1]

# Função para realizar mutação
def mutar(individuo):
```

```
      if random.random() < TAXA_MUTACAO:
      i, j = sorted(random.sample(range(1,len(individuo)-1),2))
      individuo[i:j+1] = reversed(individuo[i:j+1])
      return individuo

# Função para cruzamento crossover-ox
def cruzamento(pai1,pai2):
      tamanho = len(pai1)
      comeco, fim = sorted(random.sample(range(1, tamanho -1),2))
      filho = [-1] * tamanho
      filho[comeco:fim] = pai1[comeco:fim]
      genes_pai1 = set(filho[comeco:fim])
      restantes = [gene for gene in pai2 if gene not in genes_pai1]
      indice = 0
      for i in range(tamanho):
            if filho[i] == -1 and indice < len(restantes):
                  filho[i] = restantes[indice]
                  indice += 1
      filho[0] = pai1[0]
      filho[-1] = pai1[-1]
      return filho

def calcular_metricas_populacao(populacao, cidades):
      solucao = min(populacao, key=lambda x: calc_custo(x, cidades))
      custo_solucao = calc_custo(solucao,cidades)
return solucao, custo_solucao

def plotar_caminho(cidades, caminho, titulo):
      plt.figure(figsize=(12, 8))
      # Extrai as coordenadas do caminho
      caminho_coords = [cidades[i] for i in caminho]
      caminho_x, caminho_y = zip(*caminho_coords)
      # Plota o caminho
      plt.plot(caminho_x, caminho_y, linestyle='-', marker='o',
            color='#4c95c2', linewidth=2, markersize=8,label="Caminho")
      plt.plot(caminho_x[0], caminho_y[0], marker='o', color='red',
            markersize=10, label="Início/Fim")
      plt.xlabel("Eixo X")
      plt.ylabel("Eixo Y")
      plt.title(titulo)
      plt.legend()
```

```
      plt.show()

# Função principal
def algoritmo_genetico(cidades):
      populacao = gerar_populacao_inicial(cidades=cidades)
      melhor_solucao, melhor_custo =calcular_metricas_populacao(
            populacao=populacao, cidades=cidades)
      solucao_inicial = melhor_solucao.copy()
      custo_inicial = float(melhor_custo)

      # Plotando gráfico da solução inicial
      print(f'Custo inicial da solução {custo_inicial}')
      plotar_caminho(cidades, melhor_solucao,
            "Solução Inicial - Caminho do Caixeiro Viajante")
      for geracao in range(QUANTIDADE_GERACOES):
            nova_populacao = [melhor_solucao]
            quantidade_individuo_cruzamento = int(
                  QUANTIDADE_INDIVIDUOS * TAXA_CRUZAMENTO)
            while len(nova_populacao) < quantidade_individuo_cruzamento:
                  pai1, pai2 = selecionar_pais_torneio(populacao,cidades)
                  filho = cruzamento(pai1,pai2)
                  filho = mutar(filho)
                  nova_populacao.append(filho)
            while len(nova_populacao) < QUANTIDADE_INDIVIDUOS:
                  individuo = random.choice(populacao)
                  filho = mutar(individuo)
                  nova_populacao.append(individuo)
            populacao = nova_populacao.copy()
            melhor_solucao_atual, melhor_custo_atual =
                  calcular_metricas_populacao(populacao,cidades)
            if melhor_custo_atual < melhor_custo:
                  melhor_solucao, melhor_custo = melhor_solucao_atual,
                        melhor_custo_atual
      return melhor_solucao, melhor_custo

# Algoritmo genético
cidades = gerar_cidades()
melhor_solucao_encontrada, melhor_custo_encontrado =
       algoritmo_genetico(cidades)
Custo inicial da solução 4765.895726084021
```

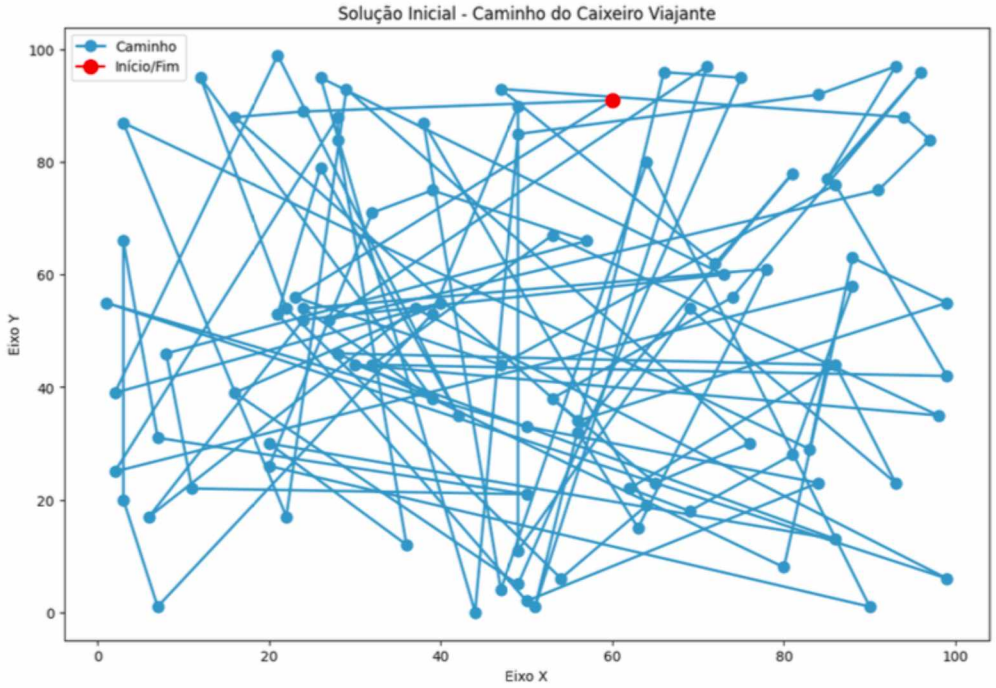


```
plotar_caminho(cidades, melhor_solucao_encontrada,
       "Solução Final - Caminho do Caixeiro Viajante")
```

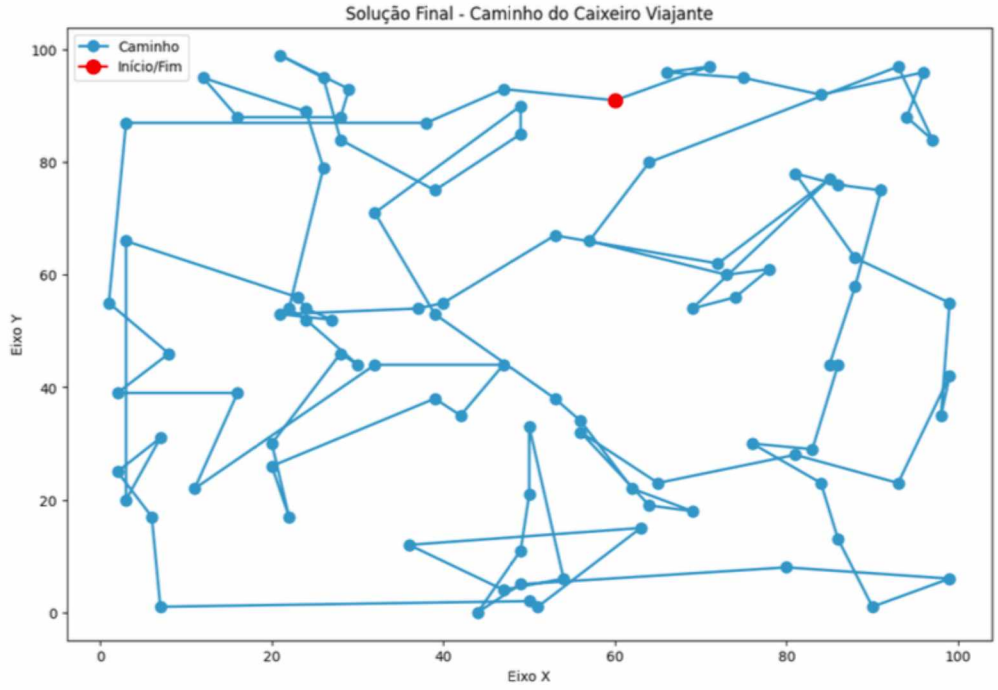


```
print(f'Custo final da solução {melhor_custo_encontrado}')
Custo final da solução 1375.535553111489
```

2. COMPARE A REPRESENTAÇÃO DE DOIS MODELOS VETORIAIS

Modelos Vetoriais

```
import numpy as np
```

```
import matplotlib.pyplot as plt
from sklearn.decomposition import PCA
from sklearn.feature_extraction.text import TfidfVectorizer
from sentence_transformers import SentenceTransformer
from mpl_toolkits.mplot3d import Axes3D

texts = [
      "The algorithm is analyzing the dataset.",
      "The algorithm is optimizing the parameters.",
      "The neural network is processing the data.",
      "The neural network is training on images.",
      "The database is storing user records.",
      "The database is retrieving user records."
]

# PCA
def apply_pca(vectors, n_components = 3):
pca = PCA(n_components)
return pca.fit_transform(vectors)

# TF-IDF
tfidf_vectorizer = TfidfVectorizer(stop_words='english')
tfidf_vectors = tfidf_vectorizer.fit_transform(texts).toarray()

# SentenceTransformer
model = SentenceTransformer("all-MiniLM-L6-v2")
embeddings = model.encode(texts)

/usr/local/lib/python3.11/dist-packages/huggingface_hub/utils/_auth.py:94:
UserWarning:
The secret `HF_TOKEN` does not exist in your Colab secrets.
To authenticate with the Hugging Face Hub, create a token in your settings
tab (https://huggingface.co/settings/tokens), set it as secret in your Google
Colab and restart your session.
You will be able to reuse this secret in all of your notebooks.
Please note that authentication is recommended but still optional to
accesspublic models or datasets.
warnings.warn(
modules.json: 0%| | 0.00/349 [00:00<?, ?B/s]
config_sentence_transformers.json: 0%| | 0.00/116 [00:00<?, ?B/s]
README.md: 0%| | 0.00/10.5k [00:00<?, ?B/s]
```

```
sentence_bert_config.json: 0%| | 0.00/53.0 [00:00<?, ?B/s]
config.json: 0%| | 0.00/612 [00:00<?, ?B/s]
model.safetensors: 0%| | 0.00/90.9M [00:00<?, ?B/s]
tokenizer_config.json: 0%| | 0.00/350 [00:00<?, ?B/s]
vocab.txt: 0%| | 0.00/232k [00:00<?, ?B/s]
tokenizer.json: 0%| | 0.00/466k [00:00<?, ?B/s]
special_tokens_map.json: 0%| | 0.00/112 [00:00<?, ?B/s]
config.json: 0%| | 0.00/190 [00:00<?, ?B/s]

# Aplicando PCA
to_pca_tfidf = apply_pca(tfidf_vectors, n_components=2)
to_pca_bert = apply_pca(embeddings,n_components=2)

# Plotando 2D
plt.figure(figsize=(12, 6))

# TF-IDF
plt.subplot(1, 2, 1)
plt.scatter(to_pca_tfidf[:, 0], to_pca_tfidf[:, 1], color='blue',
      label='TF-IDF',alpha=0.7)
for i, txt in enumerate(texts):
      plt.annotate(txt, (to_pca_tfidf[i, 0], to_pca_tfidf[i, 1]))
plt.title('TF-IDF - PCA')

# SentenceTransformer
plt.subplot(1, 2, 2)
plt.scatter(to_pca_bert[:, 0], to_pca_bert[:, 1], color='red',
      label='SentenceTransformer',alpha=0.7)
for i, txt in enumerate(texts):
      plt.annotate(txt, (to_pca_bert[i, 0], to_pca_bert[i, 1]))
plt.title('SentenceTransformer - PCA')
plt.tight_layout()
plt.show()
```

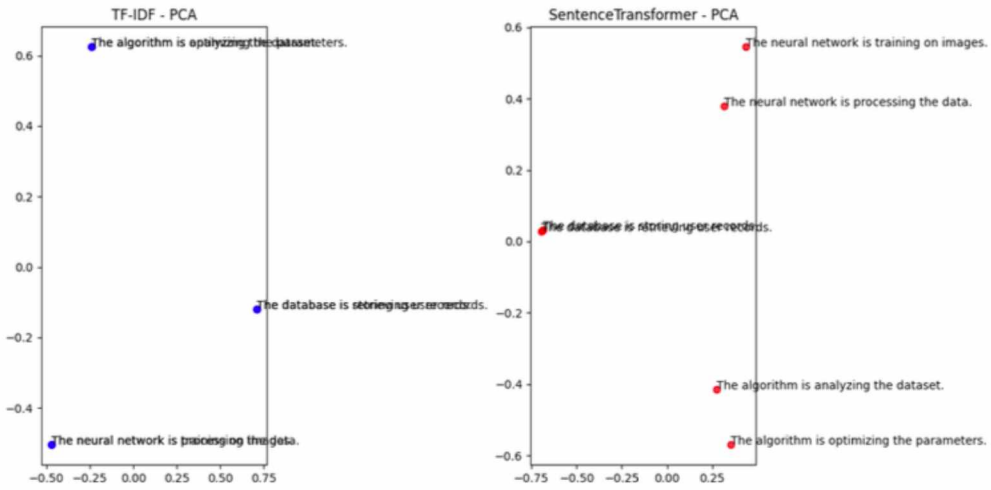


```
# Plotando 3D
# Aplicando PCA
to_pca_tfidf_3d = apply_pca(tfidf_vectors)
to_pca_bert_3d = apply_pca(embeddings)
fig = plt.figure(figsize=(12, 6))

# TF-IDF
ax1 = fig.add_subplot(121, projection='3d')
ax1.scatter(to_pca_tfidf_3d[:, 0], to_pca_tfidf_3d[:, 1],
       to_pca_tfidf_3d[:,2], color='blue', alpha=0.7)
for i, txt in enumerate(texts):
      ax1.text(to_pca_tfidf_3d[i, 0], to_pca_tfidf_3d[i, 1],
            to_pca_tfidf_3d[i,2], txt, fontsize=8)
ax1.set_title('TF-IDF - PCA (3D)')

# SentenceTransformer
ax2 = fig.add_subplot(122, projection='3d')
ax2.scatter(to_pca_bert_3d[:, 0], to_pca_bert_3d[:, 1], to_pca_bert_3d[:,
       2], color='red', alpha=0.7)
for i, txt in enumerate(texts):
      ax2.text(to_pca_bert_3d[i, 0], to_pca_bert_3d[i, 1], to_pca_bert_3d[i,
      2],txt, fontsize=8)
ax2.set_title('SentenceTransformer - PCA (3D)')
plt.show()
```

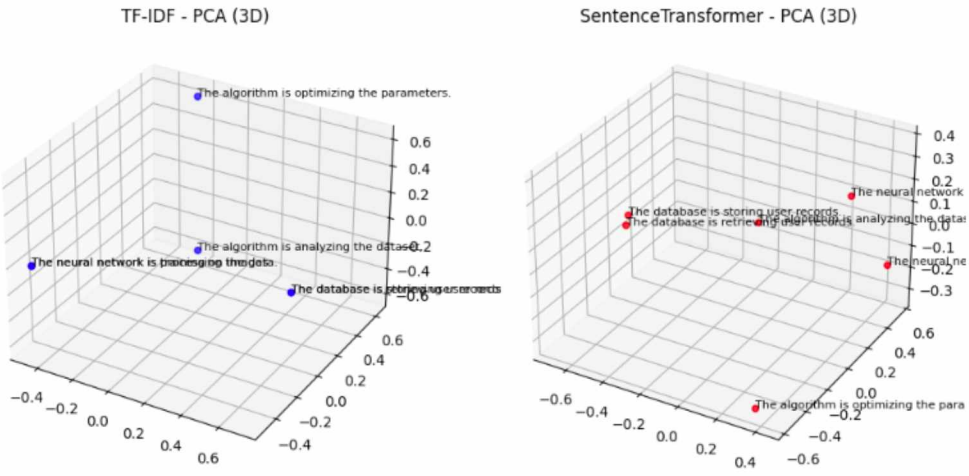
TF-IDF - PCA (3D)
The algorithm is optimizing the parameters.
The algorithm is analyzing the data.
The neural network is processing the data.
The database is storing user records.
SentenceTransformer - PCA (3D)
The neural network
The database is storing user records.
The database is retrieving user records.
The algorithm is optimizing the para