UNIVERSIDADE FEDERAL DO PARANÁ

MARCELO SILVA DA SILVA

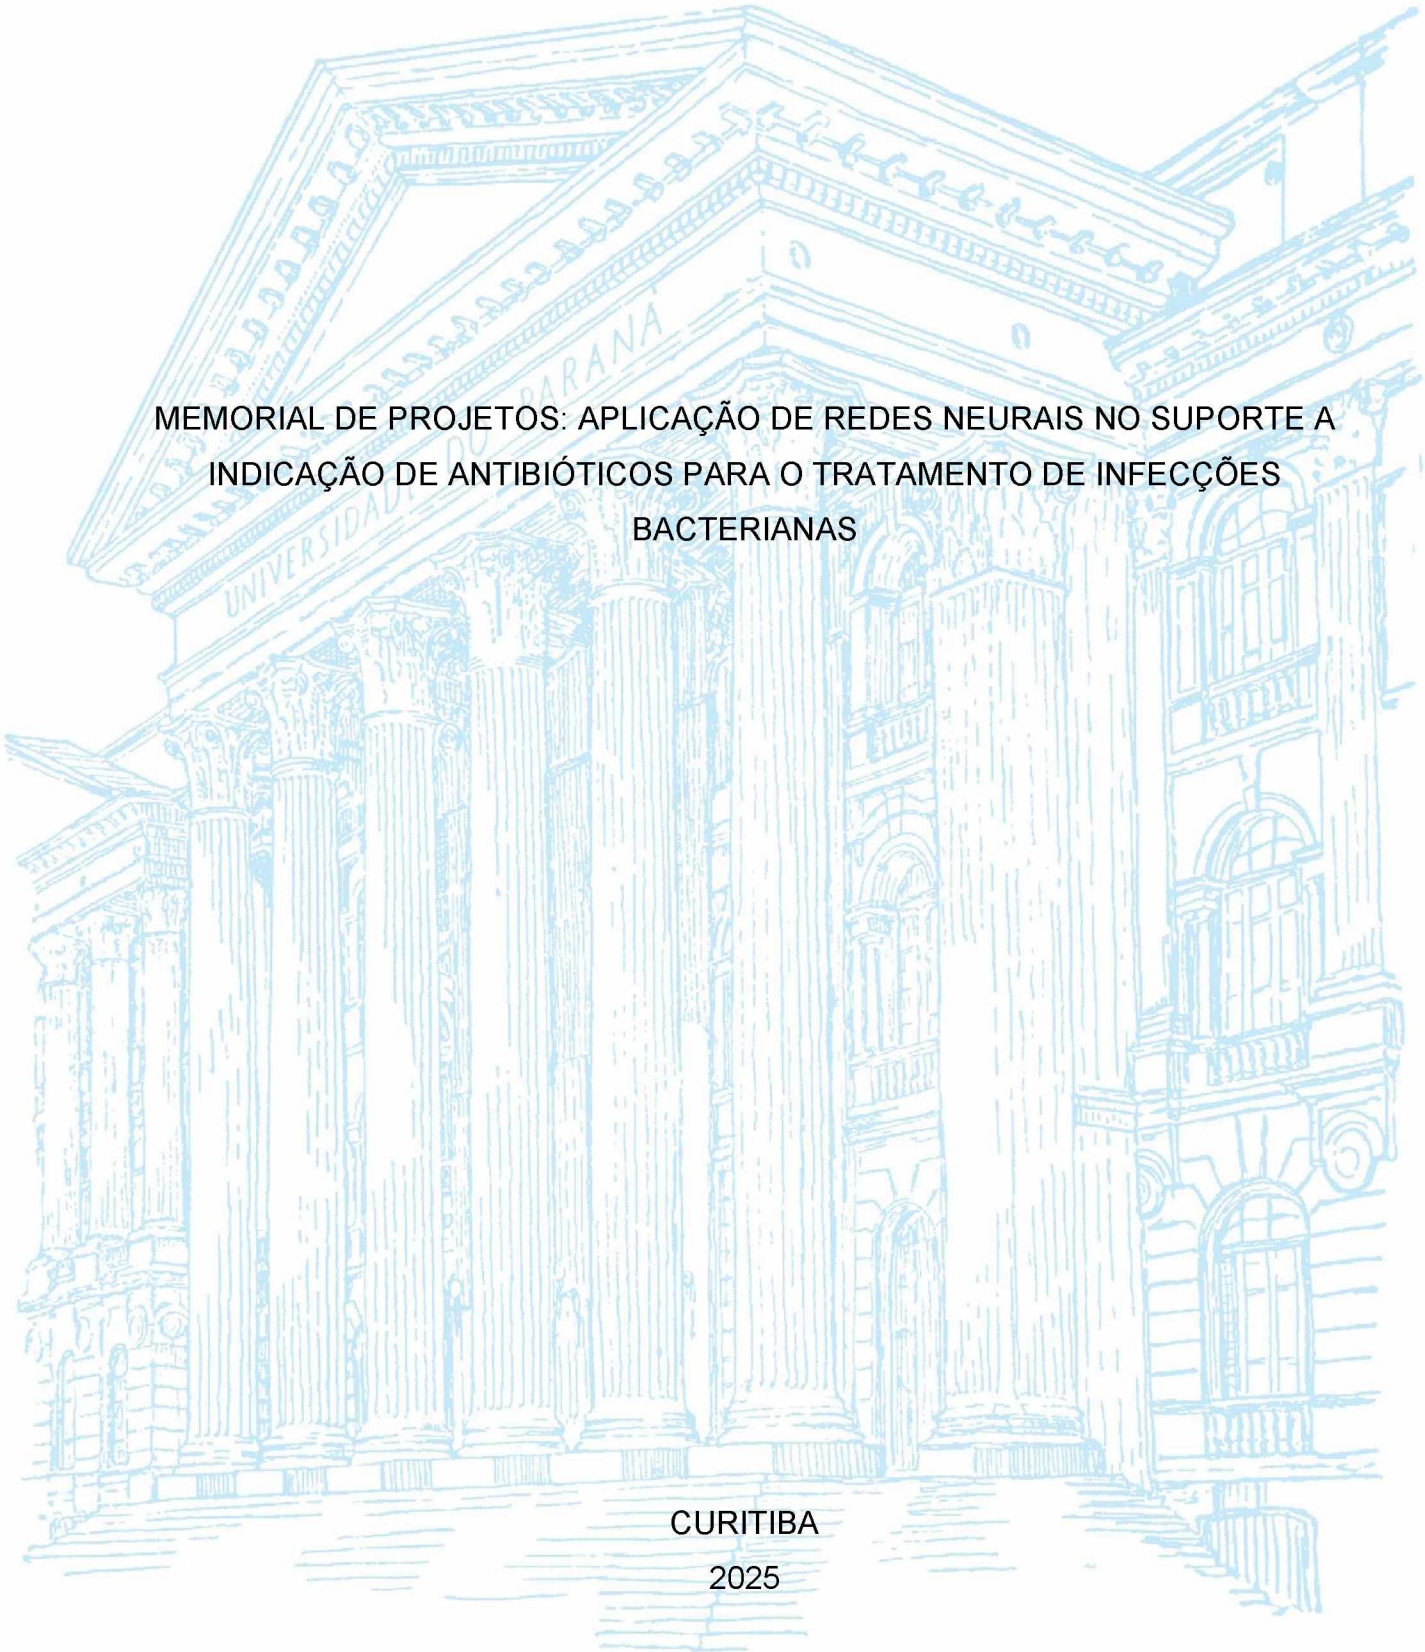

MEMORIAL DE PROJETOS: APLICAÇÃO DE REDES NEURAIS NO SUPORTE A INDICAÇÃO DE ANTIBIÓTICOS PARA O TRATAMENTO DE INFECÇÕES BACTERIANAS

CURITIBA

2025

MARCELO SILVA DA SILVA

MEMORIAL DE PROJETOS: APLICAÇÃO DE REDES NEURAIS NO SUPORTE A INDICAÇÃO DE ANTIBIÓTICOS PARA O TRATAMENTO DE INFECÇÕES BACTERIANAS

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.

Orientadora: Prof(a). Dra. Rafaela Mantovani Fontana

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 **MARCELO SILVA DA SILVA**, intitulada: **MEMORIAL DE PROJETOS: APLICAÇÃO DE REDES NEURAIS NO SUPORTE A INDICAÇÃO DE ANTIBIÓTICOS PARA O TRATAMENTO DE INFECÇÕES BACTERIANAS**, 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, 13 de Agosto de 2025.

RAFAELA MANTOVANI FONTANA
Presidente da Banca Examinadora

RAZER ANTHOM NIZER ROJAS MONTAÑO
Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

RESUMO

O presente trabalho tem como objetivo principal investigar e demonstrar a aplicabilidade de redes neurais artificiais como ferramenta de apoio à decisão na indicação de antibióticos para o tratamento de infecções bacterianas. A crescente preocupação com a resistência antimicrobiana, decorrente do uso inadequado ou excessivo de antibióticos, torna essencial o desenvolvimento de soluções tecnológicas que possam auxiliar profissionais de saúde na escolha terapêutica mais assertiva. Este memorial de projetos, elaborado no âmbito da Especialização em Inteligência Artificial Aplicada da UFPR, apresenta a concepção, o desenvolvimento e os testes de modelos de redes neurais capazes de correlacionar dados clínicos e microbiológicos com tratamentos previamente bem-sucedidos, buscando prever a indicação mais adequada para novos casos. Para isso, foram utilizados conjuntos de dados estruturados contendo informações como tipo de infecção, perfil do paciente, resultados de exames laboratoriais e histórico de prescrição. O modelo proposto foi avaliado quanto à sua acurácia, sensibilidade e capacidade preditiva em relação aos antibióticos sugeridos, além de ser comparado com abordagens tradicionais de recomendação médica. A implementação do projeto seguiu os princípios éticos do uso de dados em saúde e contou com validações clínicas preliminares para assegurar a viabilidade de sua futura integração em ambientes hospitalares ou sistemas de prescrição digital. Os resultados obtidos indicam que a aplicação de redes neurais pode representar um avanço significativo no apoio à decisão médica, contribuindo para a racionalização do uso de antibióticos e o enfrentamento da resistência bacteriana.

Palavras-chave: Redes neurais, antibióticos, infecções bacterianas, resistência antimicrobiana, infectologia.

ABSTRACT

This project aims to analyze and demonstrate the applicability of artificial neural networks as a decision support tool in recommending antibiotics for the treatment of bacterial infections. The growing concern with antimicrobial resistance, driven largely by the inadequate or excessive use of antibiotics, has made the development of intelligent solutions an urgent need in the healthcare sector. This work, part of the Postgraduate Specialization in Applied Artificial Intelligence at the Federal University of Paraná (UFPR), describes the conception, development, and evaluation of neural network models capable of correlating clinical and microbiological data with effective past treatments. The model was trained with structured datasets containing information such as infection type, patient profile, laboratory results, and prescription history. The performance of the neural networks was assessed in terms of accuracy, sensitivity, and predictive capacity, and the results were compared with traditional methods of medical recommendation. Ethical guidelines for health data usage were strictly followed, and preliminary clinical validation was conducted to verify the feasibility of integrating the solution into hospital systems or digital prescription platforms. The results show that the application of neural networks can significantly enhance clinical decision-making, optimizing the use of antibiotics and contributing to the fight against bacterial resistance.

Keywords: Neural networks; antibiotics; bacterial infections; antimicrobial resistance; infectious diseases.

SUMÁRIO

1. PARECER TÉCNICO

Neste parecer técnico será abordado o uso de redes neurais como suporte a decisão médica no uso de antimicrobianos, explicando sobre o método atual de indicação de antibióticos e a proposta utilizando inteligência artificial.

1.1 INTRODUÇÃO

A resistência antimicrobiana (RAM) é um dos maiores desafios enfrentados pela saúde pública mundial (Brasil, 2019). De acordo com a Organização Mundial da Saúde (OMS), a resistência antimicrobiana tornou-se uma ameaça significativa para a saúde pública, com uma estimativa de 1,27 milhões de mortes diretamente relacionadas com a questão em 2019, e 4,95 milhões de mortes envolvendo a resistência antimicrobiana. A OMS estima que, além de causar inúmeras mortes e incapacidades, a RAM resultará num adicional de mil milhões de dólares em custos de saúde até 2050 e numa perda de Produto Interno Bruto (PIB) para o país que varia entre 1 e 3,4 mil milhões de dólares por ano até 2030, totalizando um curso mundial de 100 trilhões até 2050 (World Health Organization, 2015).

Diante do impacto que o tratamento empírico tem nos custos globais, mortalidade, tempo de hospitalização prolongado (que diminui a disponibilidade de leitos para a população), o desenvolvimento de uma ferramenta que aumente o acerto empírico é fundamental.

Diante desse cenário, torna-se urgente o desenvolvimento de ferramentas de apoio à decisão clínica que auxiliem os profissionais da saúde na escolha assertiva de tratamentos antibióticos, contribuindo para a racionalização do uso desses fármacos. O projeto apresentado no Memorial propõe a utilização de redes neurais artificiais como solução tecnológica inovadora para esse desafio.

Na maioria das infecções o tratamento é empírico, isso é, o paciente recebe o antibiótico sem que o médico saiba a bactéria, pois a identificação do microrganismo só acontece depois que finaliza a cultura, que leva entre 2 a 5 dias. No mundo, a assertividade empírica dos antibióticos em pacientes hospitalizados é de aproximadamente 50%. Isto é 50% dos pacientes que são hospitalizados recebem antibiótico errado (Tuon, 2024a). O erro nos antibióticos aumenta a mortalidade em

10%, aumenta o tempo de internação em até 15 dias, e aumenta a resistência bacteriana (Tuon, 2024b).

No procedimento atual o médico indica um antibiótico baseado nos sintomas clínicos, literatura e sua expertise. No processo com redes neurais haverá um modelo treinado com dados anamnese, dados clínicos, exames laboratoriais, e epidemiologia local, onde a predição será baseada nos dados imputados no modelo referente ao atendimento do paciente indicando o antibiótico mais adequado, sendo um suporte a decisão médica. Conforme mostra a FIGURA 1.

FIGURA 1 – Processo atual vs Processo com Redes Neurais

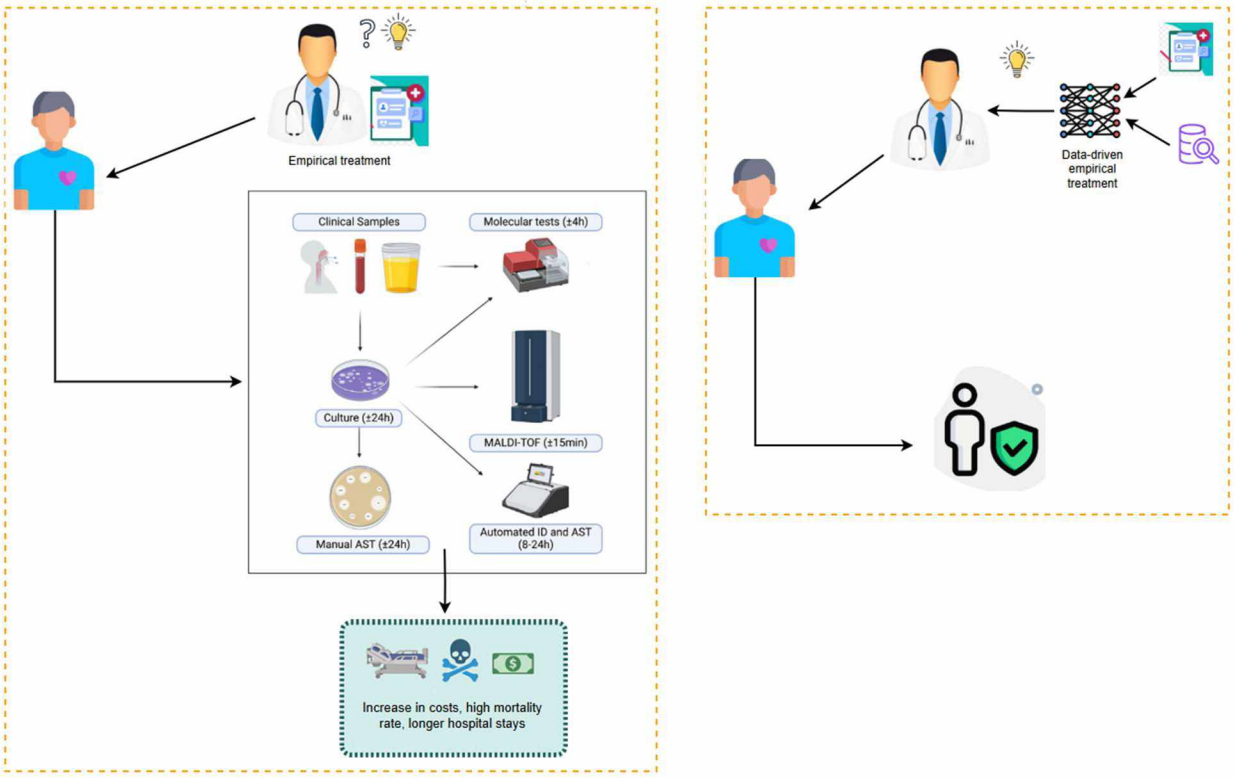

FONTE: O autor (2025).

1.2 FUNDAMENTAÇÃO E RELEVÂNCIA

A proposta está inserida na interseção entre duas áreas estratégicas: a inteligência artificial e a infectologia. O uso de redes neurais para análise de dados clínicos e microbiológicos representa um avanço importante, não apenas pela

capacidade desses modelos em identificar padrões complexos nos dados, mas também pela sua aplicabilidade prática no contexto hospitalar.

Ao utilizar datasets estruturados com informações como tipo de infecção, perfil do paciente, exames laboratoriais e histórico de prescrições, o projeto almeja treinar modelos preditivos capazes de sugerir a conduta terapêutica mais provável de sucesso. Este tipo de abordagem contribui diretamente com as iniciativas de combate à resistência bacteriana, alinhando-se a políticas públicas de saúde e diretrizes internacionais da OMS (World Health Organization, 2015).

Além disso, o trabalho apresenta um caráter interdisciplinar, integrando conhecimentos da ciência de dados, estatística, medicina e engenharia de software. Isso enriquece o projeto e amplia seu potencial de aplicabilidade em ambientes clínicos reais, sobretudo quando associado a sistemas de prescrição eletrônica.

A fase inicial, composta pelo estudo do problema, coleta de dados e análise exploratória das *features* e de sua relevância, integrou o projeto do CNPQ de Resistência Antimicrobiana (RAM), desenvolvido no Programa de Pós-Graduação em Ciências da Saúde da Pontifícia Universidade Católica do Paraná (PUCPR), sob orientação do Professor Doutor Felipe Francisco Bondan Tuon. Dessa etapa resultaram dois artigos publicados, listados nas referências do parecer técnico.

1.3 PROPOSTA AVALIADA

A proposta apresentada está alinhada dentro do contexto de um pipeline de desenvolvimento em ciência de dados, abrangeria todas as etapas esperadas em um projeto de inteligência artificial para área da saúde: preparação e anonimização dos dados, divisão entre conjunto de treino, validação e teste, escolha e ajuste de arquiteturas de redes neurais, além de métricas adequadas para avaliação, como acurácia, sensibilidade, especificidade e área sob a curva ROC (*Receiver Operating Characteristic*).

Dentro do projeto deverá ter uma etapa de validação clínica a qual será acompanhado as predições geradas pelo modelo e serão validadas pela equipe médica responsável.

A proposta de validação clínica preliminar é um diferencial importante. Embora o projeto esteja em fase exploratória, o cuidado ético na manipulação de dados sensíveis e a preocupação com a eventual aplicabilidade prática em ambientes hospitalares reforçam a maturidade da proposta.

1.4 VIABILIDADE TÉCNICA E CIENTÍFICA

Do ponto de vista técnico, a aplicação de redes neurais neste domínio seria plenamente viável. Já existem diversas bibliotecas como TensorFlow e PyTorch (Opencv, 2024) que permitem a criação de modelos robustos, e o crescimento da infraestrutura computacional, inclusive em ambientes hospitalares, viabiliza a execução dos algoritmos, podendo usar também técnicas de **N**LP (Deekshith, 2021) com LLMs e agentes inteligentes consumindo MCPs (Hou, 2025) para buscar dados e enriquecer a resposta final não só com a predição do antibiótico a ser administrado, mas também com informações complementares que auxiliem nesta decisão.

Do ponto de vista científico, o projeto estaria alinhado com a literatura atual sobre aprendizado de máquina aplicado à saúde (Miot, 2021). A utilização de modelos supervisionados para recomendação terapêutica é um campo em ascensão, e a proposta em questão contribuiria de forma significativa ao oferecer uma solução voltada especificamente ao uso racional de antibióticos, algo ainda pouco explorado no cenário nacional.

1.5 CONSIDERAÇÕES FINAIS

Este parecer técnico apresentou uma proposta que aborda a utilização de redes neurais para apoio à indicação de antibióticos, com potencial de contribuir para avanços na prática clínica, direcionando-a para abordagens mais precisas, seguras e personalizadas.

Como trabalhos futuros recomenda-se a continuidade do projeto com aprofundamento nas etapas de validação clínica e, em fases futuras, a integração com sistemas eletrônicos de prontuário para testes em ambiente controlado. Está prevista a incorporação de técnicas de Processamento de Linguagem **N**atural (PL**N**) para

análise dos dados coletados nas anamneses e nos exames clínicos e laboratoriais, epidemiologia local de forma a retroalimentar as redes neurais e aperfeiçoar o modelo. O projeto mantém alinhamento com as demandas atuais da saúde digital e com os objetivos da Especialização em Inteligência Artificial Aplicada da UFPR.

REFERÊNCIAS

BRASIL. Ministério da Saúde. Agência Nacional de Vigilância Sanitária (ANVISA). Plano Nacional de Prevenção e Controle da Resistência aos Antimicrobianos no Âmbito da Saúde Única (PAN-BR). Brasília: **Ministério da Saúde**, 2019. Disponível em: https://www.gov.br/anvisa. Acesso em: 18 abr. 2025.

DEEKSHITH, Alladi. Advances in Natural Language Processing: A Survey of Techniques. **International Journal of Innovations in Engineering Research and Technology (IJIERT)**, v. 8, n. 3, p. 74–?, mar. 2021. Acesso em: 04 fev. 2025.

HOU, Xinyi; ZHAO, Yanjie; WANG, Shenao; WANG, Haoyu. Model Context Protocol (MCP**): Landscape, Security Threats, and Future Research Directions**. arXiv, 30 mar. 2025. Disponível em: arXiv. Acesso em: 03 jun. 2025.

OPENCV. *PyTorch vs TensorFlow: Comparative Guide of AI Frameworks 2025*. **OpenCV.org**, 2024. Disponível em: https://opencv.org/blog/pytorch-vs-tensorflow/. Acesso em: 11 mar. 2025.

MIOT, Hélio Amante. Computação aplicada à medicina: conceitos fundamentais de inteligência artificial e aprendizado de máquina. **Jornal Brasileiro de Pneumologia**, São Paulo, v. 47, n. 2, 2021. Disponível em: https://www.scielo.br/j/jbpneu/a/kBgy3X9kBjVZPvRR8hZBjPb. Acesso em: 18 abr. 2025.

TUON FF, ZEQUINAO T, da SILVA MS, SILVA KO**.** eHealth and mHealth in Antimicrobial Stewardship Programs**. Digit Biomark**. 2024 Sep 20;8(1):194-206. doi: 10.1159/000541120. PMID: 39473804; PMCID: PMC11521536.

TUON FF, ZEQUINAO T, da SILVA MS, SILVA KO. eHealth and mHealth in Antimicrobial Stewardship to Reduce Mortality in Empirical Antimicrobial Therapy and a Systematic Review with a Meta-Analysis of Adequate Therapy. **Infect Dis Rep**. 2024 Aug 1;16(4):707-723. doi: 10.3390/idr16040054. PMID: 39195005; PMCID: PMC11353792.

WORLD HEALTH ORGANIZATION. Global action plan on antimicrobial resistance. Geneva: **WHO**, 2015. Disponível em: https://www.who.int/publications/i/item/9789241509763. Acesso em: 18 abr. 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.

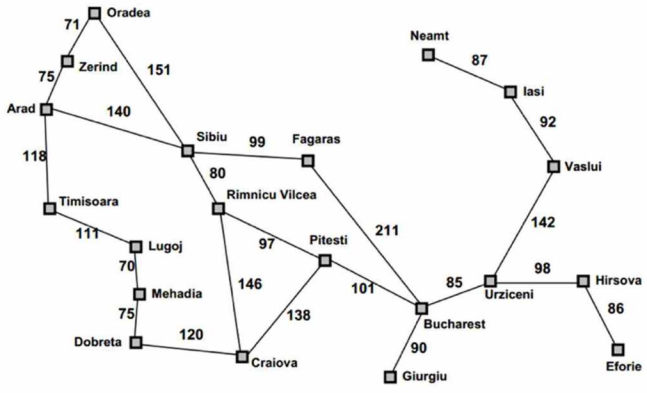

Arad	366	**Mehadia**	241
Bucareste	0	**Neamt**	234
Craiova	160	**Oradea**	380
Drobeta	242	**Pitesti**	100
Eforie	161	**Rimnicu Vilcea**	193
Fagaras	176	**Sibiu**	253
Giurgiu	77	**Timisoara**	329
Hirsova	151	**Urziceni**	80
Iasi	226	**Vaslui**	199
Lugoj	244	**Zerind**	374

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.

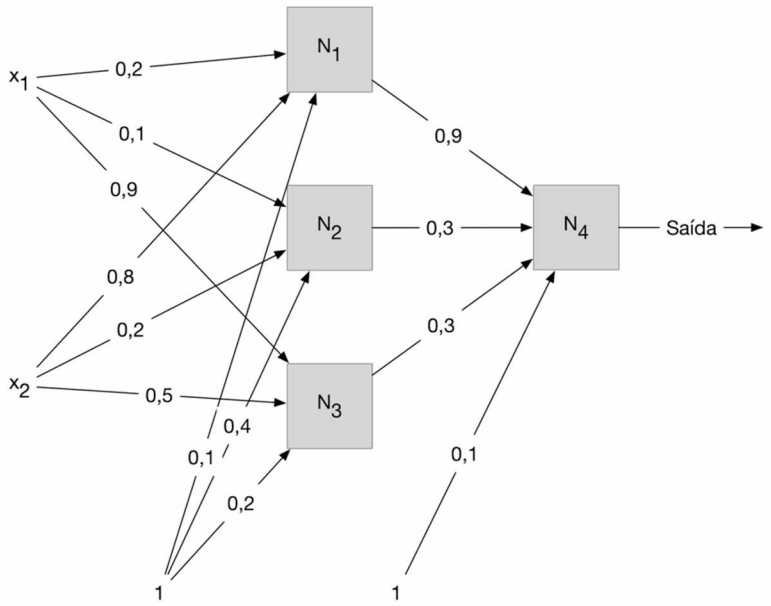

Os neurônios N_1, N_2 e N_3 possuem função de ativação linear. Já N_4 possui função de ativação tangente hiperbólica (pesquise a fórmula e aplique).

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) Inteligência Artificial (IA) é um campo da ciência da computação que se concentra no desenvolvimento de sistemas e algoritmos capazes de realizar tarefas que normalmente exigiriam inteligência humana. Isso inclui habilidades como aprendizado, raciocínio, resolução de problemas, compreensão de linguagem natural, reconhecimento de padrões, tomada de

decisões e muito mais. Os sistemas de IA são projetados para analisar grandes quantidades de dados, identificar padrões e tendências, aprender com exemplos passados e tomar decisões ou fornecer insights baseados nesses dados. Existem várias abordagens e técnicas dentro da IA incluindo aprendizado de máquina, redes neurais, lógica fuzzy, algoritmos genéticos, processamento de linguagem natural, visão computacional, entre outras. A IA tem uma ampla gama de aplicações em diversos setores, incluindo medicina, finanças, manufatura, automotivo, jogos, assistentes virtuais, entretenimento e muito mais. Seu objetivo final é criar sistemas que possam imitar a inteligência humana de maneira eficaz em várias tarefas e contextos.

b)

i) - A citação da frase "desenvolvimento de sistemas e algoritmos capazes de realizar tarefas que normalmente exigiriam inteligência humana", por si só já assinala o uso da abordagem de "Pensar como os humanos" indicando a busca por desenvolver algoritmos que se aproximem deste estado.

ii) – A resposta cita também que a IA é projetada para analisar grandes quantidades de dados o que indica a abordagem "Pensar racionalmente".

iii) – A observação que a IA possui uma ampla gama de aplicações em diversos setores nos indica a abordagem "Agir como humanos"

iv) – O texto fala sobre que as IA são projetadas para aprender por exemplos e tomar decisões baseadas nesses dados, essa abordagem está relacionada a "Agir racionalmente"

c) Os conteúdos relacionados as repostas citam que o ChatGPT pode ser definido como um modelo de linguagem que tem como base IA e utiliza redes neurais, machine learning e avançados algoritmos de processamento de linguagem natural. Com foco em diálogos virtuais, sendo a evolução dos antigos chatbots, tendo sido treinado com grandes volumes de dados ou qual consegue manter uma conversa humana em linguagem natural, respondendo perguntas feitas pelos usuários, muito ú l para facilitar o acesso a informações e códigos a par r de seus dados.

Porém criticado por possivelmente u lizar informações autorais ao qual indicaria plagio e por não indicar as fontes u lizadas para montar o racional da resposta, deixando assim lacunas e questionamento sobre as origens dos dados.
Outro ponto é relação aos dados por nós imputados nas perguntas ao ChatGPT, elas são usadas para armazenamento e utilização posterior? São processadas e descartadas? As fontes nos indicam que temos que evitar de compartilhar informações confidenciais.
O ChatGPT possui limitações: Bias: pois devido ao treinamento com grandes volumes de dados desatualizados ou enviesados, Contexto limitado: ele pode ter ainda dificuldades em responder nuances complexas ou informações implícitas.
Referências:

ChatGPT: o que é, como funciona e exemplos de como usar (investnews.com.br)
ChatGPT é seguro? Entenda como funciona (santodigital.com.br)
ChatGPT: o que é, como funciona e limitações (V.6. N.6. P.2, 2023) – Blog UFABC Divulga Ciência

d) Eu classificaria o ChatGPT como um avanço tecnológico, devendo ser considerado tal qual a revolução industrial, uma fonte que não irá fazer o trabalho para o ser humano, mas facilitará e auxiliará dando agilidade em trabalhos "mecânicos" por assim dizer, permitindo que o tempo seja aproveitado para desenvolvimento de novas ideias e criações. Baseado nas 4 abordagens estudadas podemos indicar que o ChatGPT as simula, tentando ao buscar as respostas ele agem como "Pensar como os humanos", e dentro das grandes quantidades de material ele usa essa abordagem para separar os conteúdos como se pensasse racionalmente, claro que devido as suas limitações ainda não tem como ele agir como humanos, mas devido ao seu conhecimento os humanos podem aplicar seu conhecimento, o agir racionalmente pode ser atingido com maior facilidade uma vez que sua análise é baseada em dados.

2) Resposta:

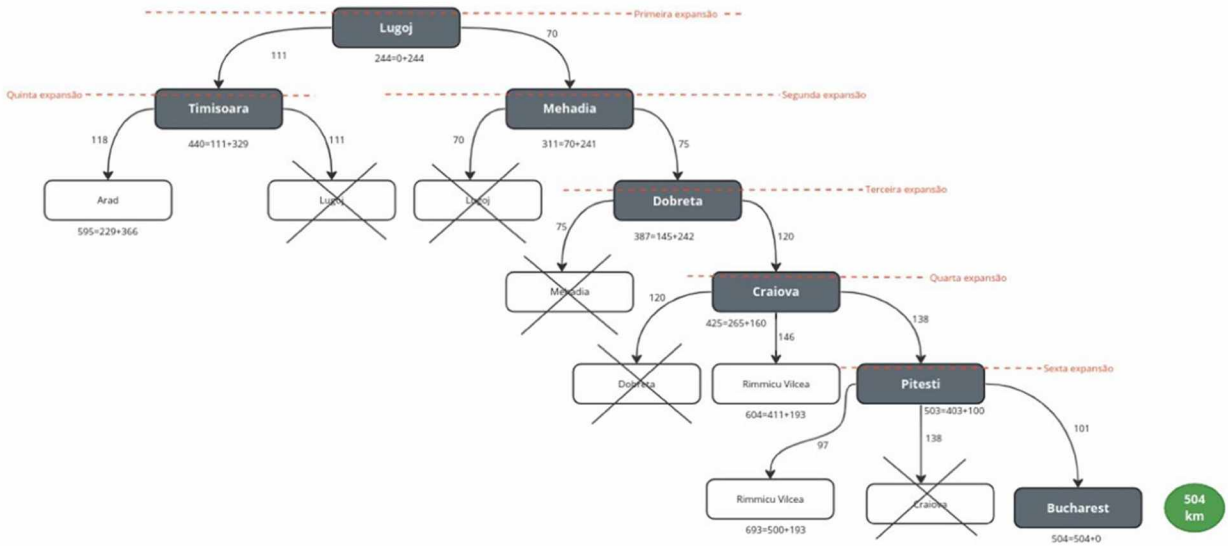

3) Resposta:

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

R4: r → p	Equivalência Implicação R3
R5: q → p	Silogismo Hipotético R2, R4
R6: (q → p) ^ (p → q)	Conjunção R5, R1
R7: q ↔ p	Equivalência Bicondicional R6

4) Resposta:

a) (6,25 pontos) Valor de saída do neurônio N1
Resposta: N1 = 0,3

b) (6,25 pontos) Valor de saída do neurônio N2
Resposta: N2 = 0,3

c) (6,25 pontos) Valor de saída do neurônio N3
Resposta: N3 = -2

d) (6,25 pontos) Valor de saída da rede como um todo
Resposta: Saída = -0,1391

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

F). Há valores faltantes em todas as colunas com a quantidade de 65.245 registros por coluna, removido as linhas onde era vazia para todas as colunas. Há 2 valores duplicados. Criado categorias para separar colunas numéricas e categóricas.

2 - Visualização dos dado

E). O modelo de engrenagem automática é mais caro que o modelo de engrenagem manual. A marca Renault tem o menor preço médio de carros com engrenagem automática. A marca Fiat tem o menor preço médio de carros com engrenagem manual.

G). Diesel é o tipo de combustível mais caro. Alcool é o tipo de combustível mais barato. A marca Ford tem o menor preço médio de carros com combustível diesel. A marca Renault tem o menor preço médio de carros com combustível gasolina. A marca Ford tem o menor preço médio de carros com combustível álcool.

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

F). A variável engine_size é a mais importante para todos os modelos.

G). O modelo Xgboost.

H). O modelo Xgboost obteve o melhor resultado com as métricas de avaliação MSE(Ccalcula o erro quadrático médio das predições do nosso modelo. Quanto maior o MSE, pior é o modelo.) e R^2(Métrica que varia entre 0 e 1 e é uma razão que indica o quão bom o nosso modelo. Quanto maior seu valor, melhor é o modelo).

COMANDOS

In [1]:
```
import pandas as pd
import seaborn as sns
import matplotlib.pyplot as plt

import warnings
warnings.filterwarnings('ignore')
```

In [2]:
```
# 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
```

In [3]:
```
# Função read_csv para importar os dados da pasta do computador
dados = pd.read_csv('precos_carros_brasil.csv')
```

In [4]:
```
dados.columns
```

Out[4]:
```
Index(['year_of_reference', 'month_of_reference', 'fipe_code',
       'authentication', 'brand', 'model', 'fuel', 'gear', 'engine_size',
       'year_model', 'avg_price_brl'],
      dtype='object')
```

In [5]:
```
dados.head()
```

Out[5]:

	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

In [6]:
```
# Observando número de linhas e colunas
dados.shape
```

Out[6]:
```
(267542, 11)
```

---

1. Análise Exploratória dos Dados (AED)

In [7]:
```
# Imprime o tipo de dado em cada coluna: object - variáveis categóricas; float64 e int64 - variáveis numéricas
dados.dtypes
```

Out[7]:
```
year_of_reference     float64
month_of_reference     object
fipe_code              object
authentication         object
brand                  object
model                  object
fuel                   object
gear                   object
engine_size            object
year_model            float64
avg_price_brl         float64
dtype: object
```

In [8]:
```
# Verificando se existem valores faltantes nos dados
dados.isna().any()
```

Out[8]:
```
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
```

In [9]:
```
# Verificando a quantidade de valores faltantes por coluna
dados.isna().sum()
```

Out[9]:
```
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
```

In [10]:
```
# Verificar a quantidade de linhas vazias em todas as colunas
dados.isnull().all(axis=1).sum()
```

Out[10]:
```
65245
```

In [11]:
```
# Remover linhas vazias de todas as colunas
dados = dados.dropna(how='all')
```

In [12]:
```
# Verificando a quantidade de valores faltantes por coluna
dados.isna().sum()
```

Out[12]:
```
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
```

In [13]:
```
dados['engine_size'] = dados['engine_size'].str.replace(',', '.')
```

In [14]:
```
#Valores floats para inteiros
dados['year_of_reference'] = dados['year_of_reference'].astype(int)
dados['year_model'] = dados['year_model'].astype(int)
dados['engine_size'] = dados['engine_size'].astype(float)
```

In [15]:
```
dados.dtypes
```

Out[15]:
```
year_of_reference       int64
month_of_reference     object
fipe_code              object
authentication         object
brand                  object
model                  object
fuel                   object
gear                   object
engine_size           float64
year_model              int64
avg_price_brl         float64
dtype: object
```

In [16]:
```
dados.head()
```

Out[16]:

	year_of_reference	month_of_reference	fipe_code	authentication	brand	model	fuel	gear	engine_size	year_model	avg_price_brl
0	2021	January	004001-0	cfzlctzfwrcp	GM - Chevrolet	Corsa Wind 1.0 MPFI / EFI 2p	Gasoline	manual	1.0	2002	9162.0
1	2021	January	004001-0	cdqwxwpw3y2p	GM - Chevrolet	Corsa Wind 1.0 MPFI / EFI 2p	Gasoline	manual	1.0	2001	8832.0
2	2021	January	004001-0	cb1t3xwwj1xp	GM - Chevrolet	Corsa Wind 1.0 MPFI / EFI 2p	Gasoline	manual	1.0	2000	8388.0
3	2021	January	004001-0	cb9gct6j65r0	GM - Chevrolet	Corsa Wind 1.0 MPFI / EFI 2p	Alcohol	manual	1.0	2000	8453.0
4	2021	January	004003-7	g15wg0gbz1fx	GM - Chevrolet	Corsa Pick-Up GL/ Champ 1.6 MPFI / EFI	Gasoline	manual	1.6	2001	12525.0

In [17]:
```
# Verificando se temos valores duplicados
dados.duplicated().sum()
```

Out[17]:
```
2
```

In [18]:
```
# Removendo valores duplicados
dados.drop_duplicates(inplace=True)
```

In [19]:
```
# Verificando se temos valores duplicados
dados.duplicated().sum()
```

Out[19]:
```
0
```

In [20]:
```
# nº de linhas e colunas após mudanças.
dados.shape
```

Out[20]:
```
(202295, 11)
```

In [21]:
```
# Criando categorias para separar colunas numéricas e categóricas: facilita a AED
numericas_cols = [col for col in dados.columns if dados[col].dtype != 'object']
categoricas_cols = [col for col in dados.columns if dados[col].dtype == 'object']
```

In [22]:
```
# Resumo das variáveis numéricas - Imprime alguns valores de medidas de tendências centrais
dados[numericas_cols].describe()
```

Out[22]:

	year_of_reference	engine_size	year_model	avg_price_brl
count	202295.000000	202295.000000	202295.000000	202295.000000
mean	2021.564695	1.822302	2011.271514	52756.765713
std	0.571904	0.734432	6.376241	51628.912116
min	2021.000000	1.000000	2000.000000	6647.000000
25%	2021.000000	1.400000	2006.000000	22855.000000
50%	2022.000000	1.600000	2012.000000	38027.000000
75%	2022.000000	2.000000	2016.000000	64064.000000
max	2023.000000	6.200000	2023.000000	979358.000000

In [23]:
```
# Resumo das variáveis categóricas - Imprime alguns valores de estatística descritiva
dados[categoricas_cols].describe()
```

Out[23]:

	month_of_reference	fipe_code	authentication	brand	model	fuel	gear
count	202295	202295	202295	202295	202295	202295	202295
unique	12	2091	202295	6	2112	3	2
top	January	001216-5	7hbnjmj9z5dqw	Fiat	Palio Week. Adv/Adv TRYON 1.8 mpi Flex	Gasoline	manual
freq	24260	425	1	44962	425	168684	161883

In [24]:
```
# Verificando a quantidade de valores faltantes por coluna
dados.isna().sum()
```

Out[24]:
```
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
```

---

2 Visualização dos dados

In [25]:
```
# Contagem do nº de marcas de carros
dados['brand'].value_counts()
```

Out[25]:
```
brand
Fiat              44962
VW - VolksWagen   44312
GM - Chevrolet    38590
Ford              33150
Renault           29191
Nissan            12090
Name: count, dtype: int64
```

In [26]:
```
# Gráfico da distribuição da quantidade de carros por marca
plt.figure(figsize=(20,10))
plt.bar(dados['brand'].unique(), dados['brand'].value_counts()) # plt.bar para gráfico de barras. Variáveis nos eixos X e Y
plt.title('Distribuição de carros por marca') # plt.title para inserir título no gráfico
plt.ylabel('Total de carros') # # plt.ylabel para inserir título no gráfico
```

Out[26]:
```
Text(0, 0.5, 'Total de carros')
```

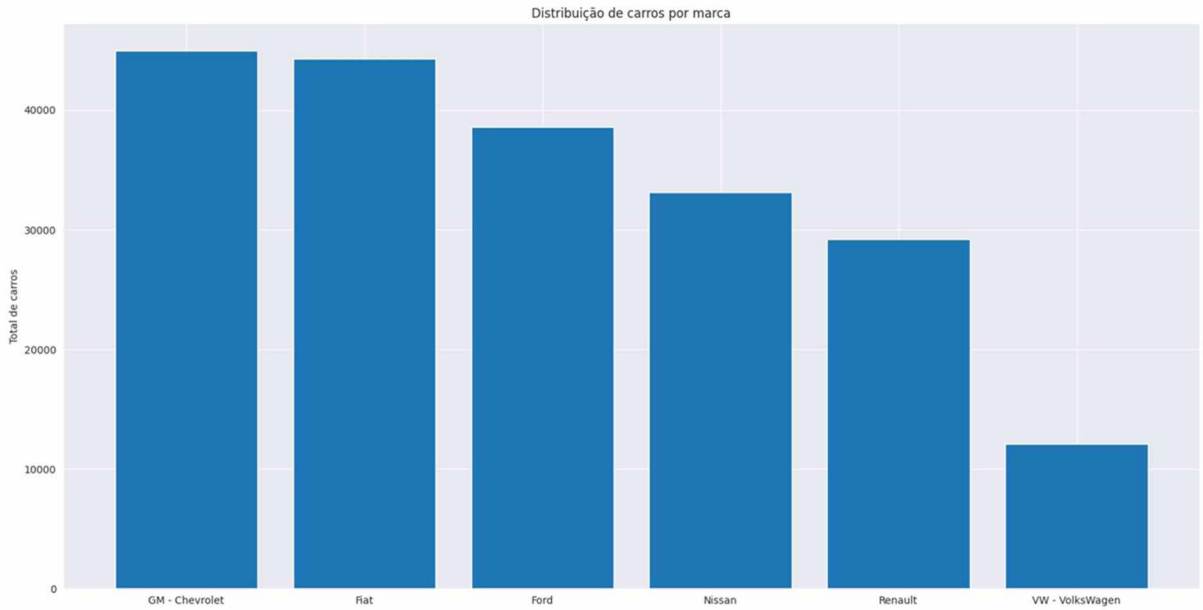

In [27]:
```
# Gráfico da distribuição da quantidade de carros por tipo de engrenagem do carro
plt.figure(figsize=(20,10))
plt.bar(dados['gear'].unique(), dados['gear'].value_counts()) # plt.bar para gráfico de barras. Variáveis nos eixos X e Y
plt.title('Distribuição de carros por tipo de engrenagem') # plt.title para inserir titulo no gráfico
```

Out[27]:
```
Text(0.5, 1.0, 'Distribuição de carros por tipo de engrenagem')
```

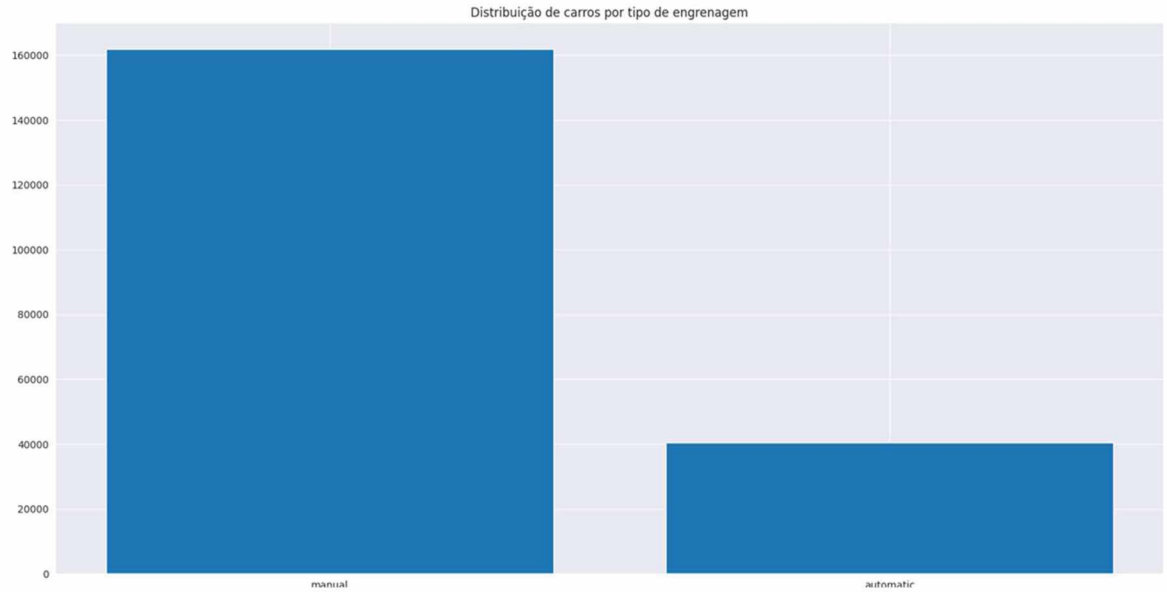

In [28]:
```
dados.head()
```

Out[28]:

	year_of_reference	month_of_reference	fipe_code	authentication	brand	model	fuel	gear	engine_size	year_model	avg_price_brl
0	2021	January	004001-0	cfzlctzfwrcp	GM - Chevrolet	Corsa Wind 1.0 MPFI / EFI 2p	Gasoline	manual	1.0	2002	9162.0
1	2021	January	004001-0	cdqwxwpw3y2p	GM - Chevrolet	Corsa Wind 1.0 MPFI / EFI 2p	Gasoline	manual	1.0	2001	8832.0
2	2021	January	004001-0	cb1t3xwwj1xp	GM - Chevrolet	Corsa Wind 1.0 MPFI / EFI 2p	Gasoline	manual	1.0	2000	8388.0
3	2021	January	004001-0	cb9gct6j65r0	GM - Chevrolet	Corsa Wind 1.0 MPFI / EFI 2p	Alcohol	manual	1.0	2000	8453.0
4	2021	January	004003-7	g15wg0gbz1fx	GM - Chevrolet	Corsa Pick-Up GL/ Champ 1.6 MPFI / EFI	Gasoline	manual	1.6	2001	12525.0

In [29]:
```
# Calculando a média por ano e mês
media_preço_mes = dados.groupby(['month_of_reference','year_of_reference'])['avg_price_brl'].mean().round(0) # round para arrendodar
media_preço_mes.head()
# Utilizando a função reset_index para criar uma ordem e facilitar a criação do gráfico
media_preço_mes = media_preço_mes.reset_index(name='Preço médio')
media_preço_mes.rename(columns={'month_of_reference':'Mês de referencia'}, inplace=True)
media_preço_mes.head()
```

Out[29]:

	Mês de referencia	year_of_reference	Preço médio
0	April	2021	44451.0
1	April	2022	57150.0
2	August	2021	49363.0
3	August	2022	57924.0
4	December	2021	53674.0

In [30]:
```
# Função para atribuir valores numéricos com base nos meses
def atribuir_valor_numerico(categoria):
    if categoria == 'January':
        return 1
    elif categoria == 'February':
        return 2
    elif categoria == 'March':
        return 3
    elif categoria == 'April':
        return 4
    elif categoria == 'May':
        return 5
    elif categoria == 'June':
        return 6
    elif categoria == 'July':
        return 7
    elif categoria == 'August':
        return 8
    elif categoria == 'September':
        return 9
    elif categoria == 'October':
        return 10
    elif categoria == 'November':
        return 11
    elif categoria == 'December':
        return 12
    else:
        return None

media_preço_mes['Mês de referencia - numerico'] = media_preço_mes['Mês de referencia'].apply(atribuir_valor_numerico)
```

In [31]:
```
filtro_ano_2022 = media_preço_mes[media_preço_mes['year_of_reference'] == 2022]
filtro_ano_2022.sort_values(by='Mês de referencia - numerico', inplace=True)
```

In [32]:
```
filtro_ano_2022
```

Out[32]:

	Mês de referencia	year_of_reference	Preço médio	Mês de referencia - numerico
9	January	2022	54840.0	1
7	February	2022	55825.0	2
16	March	2022	56849.0	3
1	April	2022	57150.0	4
18	May	2022	57800.0	5
14	June	2022	58066.0	6
12	July	2022	57894.0	7
3	August	2022	57924.0	8
24	September	2022	58199.0	9
22	October	2022	58227.0	10
20	November	2022	58216.0	11
5	December	2022	57997.0	12

In [33]:
```
# Gráfico da evolução da média de preço dos carros ao longo dos meses de 2022 (variável de tempo no eixo X)
plt.figure(figsize=(20,10)) # Aumentar tamanho da imagem que será impressa na tela
plt.title('Evolução da média de preço dos carros ao longo dos meses de 2022') # plt.title para inserir título no gráfico
sns.barplot(x='Mês de referencia', y='Preço médio', hue='Mês de referencia', data=filtro_ano_2022, hue_order=list(filtro_ano_2022['Mês de referencia'].to_numpy()))
plt.xticks(rotation=45);
```

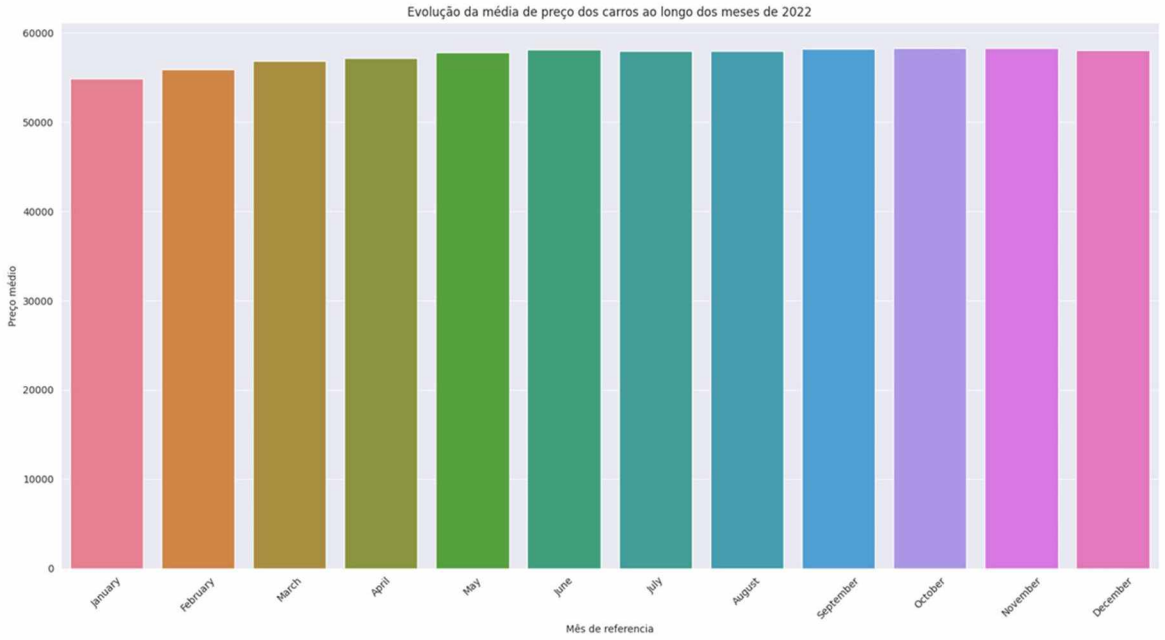

In [34]:
```
# Calculando a média por marca e tipo de engrenagem
media_preço_engrenagem = dados.groupby(['brand','gear'])['avg_price_brl'].mean().round(0) # round para arrendodar
media_preço_engrenagem.head()
# Utilizando a função reset_index para criar uma ordem e facilitar a criação do gráfico
media_preço_engrenagem = media_preço_engrenagem.reset_index(name='Preço médio')
media_preço_engrenagem.rename(columns={'brand':'Marca'}, inplace=True)
media_preço_engrenagem.rename(columns={'gear':'Tipo de engrenagem'}, inplace=True)
media_preço_engrenagem.head()
```

Out[34]:

	Marca	Tipo de engrenagem	Preço médio
0	Fiat	automatic	97397.0
1	Fiat	manual	39694.0
2	Ford	automatic	84769.0
3	Ford	manual	51784.0
4	GM - Chevrolet	automatic	88157.0

In [35]:
```
#Gere um gráfico da distribuição da média de preço dos carros por marca e tipo de engrenagem
plt.figure(figsize=(20,10)) # Aumentar tamanho da imagem que será impressa na tela
plt.title('Distribuição da média de preço dos carros por marca e tipo de engrenagem') # plt.title para inserir titulo no gráfico
sns.barplot(x='Marca', y='Preço médio', hue='Tipo de engrenagem', data=media_preço_engrenagem, hue_order=['automatic', 'manual']);
plt.xticks(rotation=45);
```

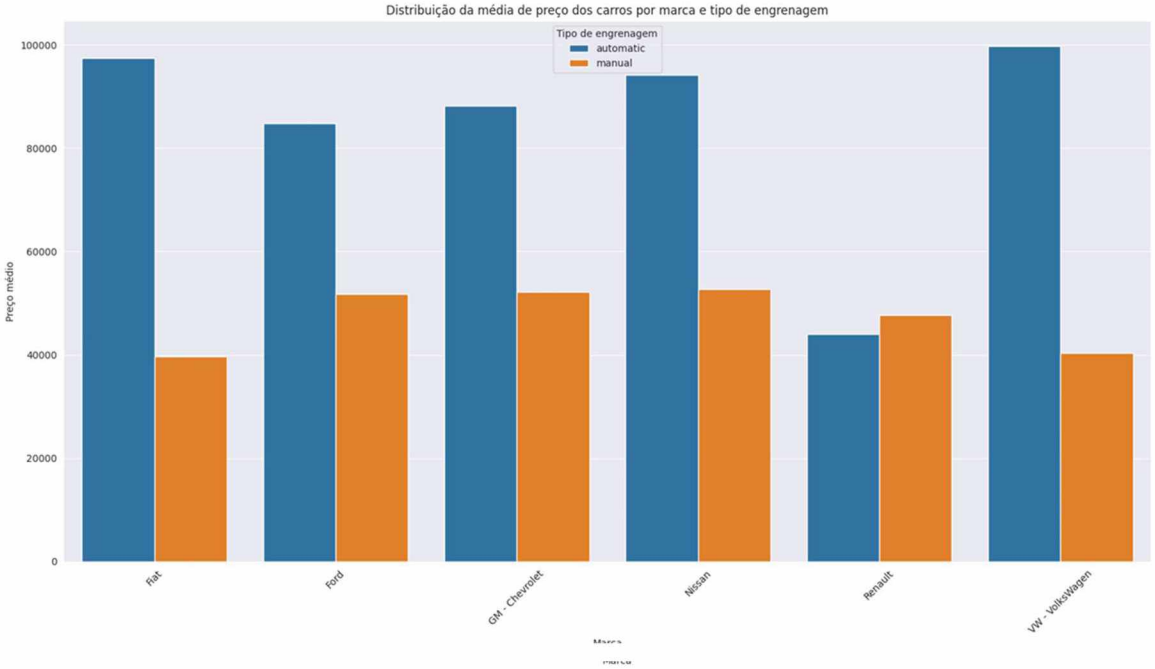

In [36]:
```
# Calculando a média por marca e tipo de combustivel
media_preço_combustivel = dados.groupby(['brand','fuel'])['avg_price_brl'].mean().round(0) # round para arrendodar
media_preço_combustivel.head()
# Utilizando a função reset_index para criar uma ordem e facilitar a criação do gráfico
media_preço_combustivel = media_preço_combustivel.reset_index(name='Preço médio')
media_preço_combustivel.rename(columns={'brand':'Marca'}, inplace=True)
media_preço_combustivel.rename(columns={'fuel':'Tipo de combustivel'}, inplace=True)
media_preço_combustivel.head()
```

Out[36]:

	Marca	Tipo de combustivel	Preço médio
0	Fiat	Alcohol	11510.0
1	Fiat	Diesel	99814.0
2	Fiat	Gasoline	37197.0
3	Ford	Alcohol	10149.0
4	Ford	Diesel	94526.0

In [37]:
```
media_preço_combustivel['Tipo de combustivel'].value_counts()
```

Out[37]:
```
Tipo de combustivel
Diesel      6
Gasoline    6
Alcohol     4
Name: count, dtype: int64
```

In [38]:
```
#Gere um gráfico da distribuição da média de preço dos carros por marca e tipo de combustivel
plt.figure(figsize=(20,10))
plt.title('Distribuição da média de preço dos carros por marca e tipo de combustivel')
sns.barplot(x='Marca', y='Preço médio', hue='Tipo de combustivel', data=media_preço_combustivel, hue_order=['Diesel', 'Gasoline', 'Alcohol', 's/n']);
plt.xticks(rotation=45);
```

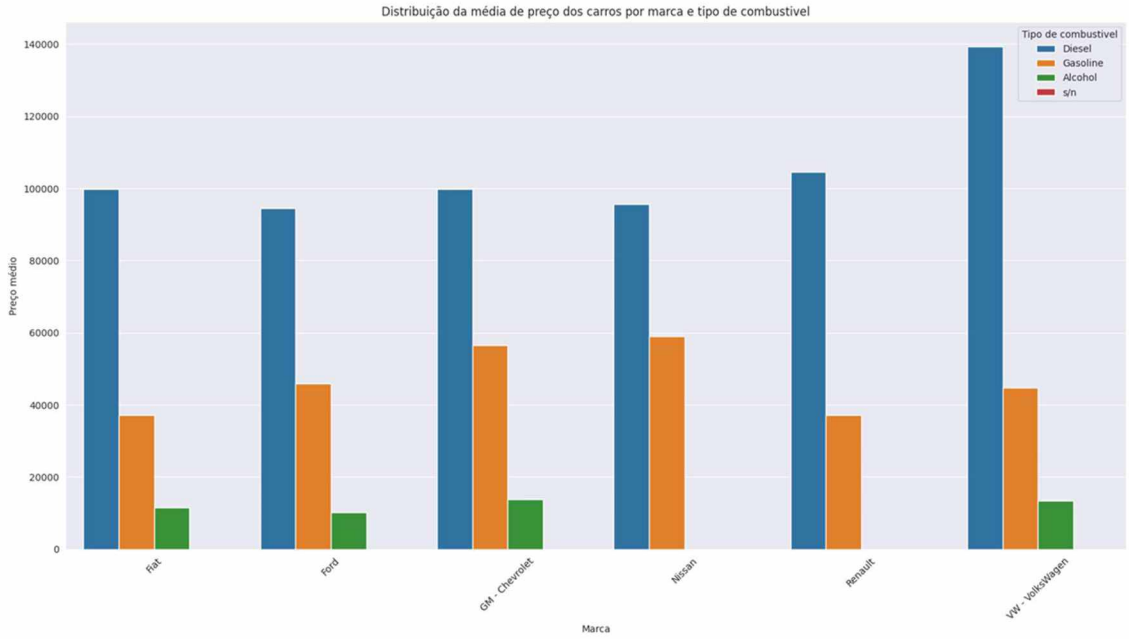

3. Aplicação de modelos de machine learning para prever o preço médio dos carros

Análise da variável resposta (também chamada de target)

```
In [39]: sns.boxplot(dados['avg_price_brl']).set_title('Variável resposta (target)')
```

```
Out[39]: Text(0.5, 1.0, 'Variável resposta (target)')
```

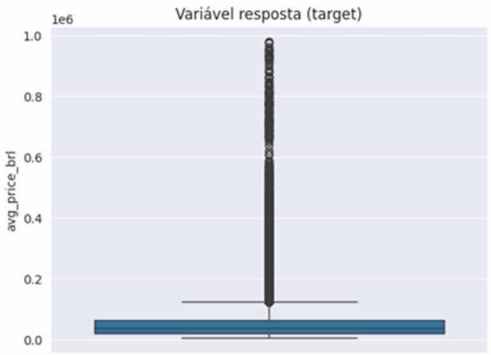

Divisão dos dados

```
In [40]: dados.columns
```

```
Out[40]: Index(['year_of_reference', 'month_of_reference', 'fipe_code',
       'authentication', 'brand', 'model', 'fuel', 'gear', 'engine_size',
       'year_model', 'avg_price_brl'],
      dtype='object')
```

```
In [41]: dados['month_of_reference_numeric'] = dados['month_of_reference'].apply(atribuir_valor_numerico)
```

```
In [42]: dados_num = dados.drop(['fipe_code', 'authentication', 'brand', 'model', 'fuel', 'gear', 'month_of_reference'],axis = 1)
dados_num.head()
```

Out[42]:

	year_of_reference	engine_size	year_model	avg_price_brl	month_of_reference_numeric
0	2021	1.0	2002	9162.0	1
1	2021	1.0	2001	8832.0	1
2	2021	1.0	2000	8388.0	1
3	2021	1.0	2000	8453.0	1
4	2021	1.6	2001	12525.0	1

In [43]:
```
sns.heatmap(dados_num.corr("spearman"), annot = True)
plt.title("Mapa de Correlação das Variáveis Numéricas\n", fontsize = 15)
plt.show()
```

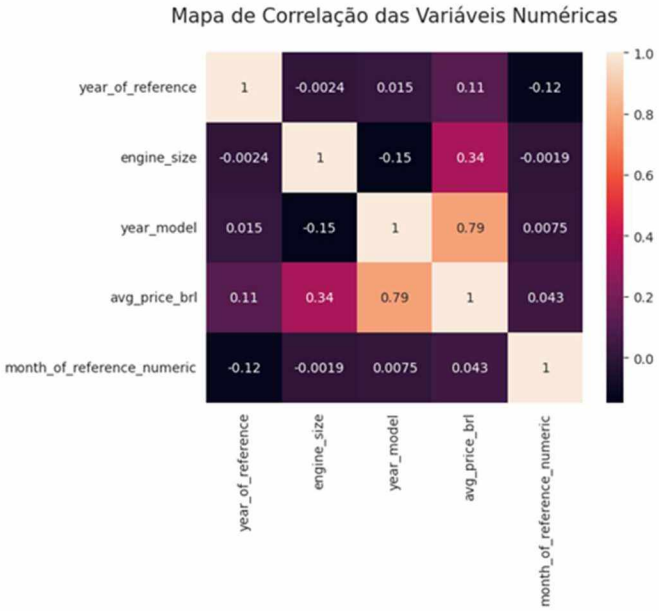

In [44]:
```
# Variável X contém apenas variáveis numéricas de interesse para a análise, excluindo a variável target
X = dados_num.drop(['avg_price_brl'],axis = 1)
X.head()
```

Out[44]:

	year_of_reference	engine_size	year_model	month_of_reference_numeric
0	2021	1.0	2002	1
1	2021	1.0	2001	1
2	2021	1.0	2000	1
3	2021	1.0	2000	1
4	2021	1.6	2001	1

In [45]:
```
# Variável Y contém apenas a variável target
Y = dados_num['avg_price_brl']
Y.head()
```

Out[45]:
```
0     9162.0
1     8832.0
2     8388.0
3     8453.0
4    12525.0
Name: avg_price_brl, dtype: float64
```

In [46]:
```
# Divisão: 30% dos dados são de teste e 70% de treinamento
X_train, X_test, Y_train, Y_test = train_test_split(X, Y, test_size = 0.25, random_state = 42)
```

In [47]:
```
# Observando os dados de treinamento
print(X_train.shape)
X_train.head(1)
```

```
(151721, 4)
```

Out[47]:

	year_of_reference	engine_size	year_model	month_of_reference_numeric
156364	2022	2.3	2020	8

In [48]:
```
# Observando os dados de teste
print(X_test.shape)
X_test.head(1)
```

```
(50574, 4)
```

Out[48]:

	year_of_reference	engine_size	year_model	month_of_reference_numeric
180633	2022	1.6	2015	11

In [49]:
```
# Observando a variável target
Y_test.head()
```

Out[49]:
```
180633    42595.0
13130     10989.0
163315     9087.0
121464    26965.0
14044     57102.0
Name: avg_price_brl, dtype: float64
```

Treinamento do modelo

Random Forest

In [50]:
```
# Algoritmo Random Forest, sem especificar nenhum parâmetro (número de árvores, número de ramificações, etc)
model_rf = RandomForestRegressor()
```

In [51]:
```
# Ajuste do modelo, de acordo com as variáveis de treinamento
model_rf.fit(X_train, Y_train)
```

Out[51]:
```
RandomForestRegressor
RandomForestRegressor()
```

In [52]:
```
# Predição dos valores de salário com base nos dados de teste
valores_preditos_rf = model_rf.predict(X_test)
```

In [53]:
```
# Valores preditos
valores_preditos_rf
```

Out[53]:
```
array([ 47503.1939779 ,  12299.18379675,  14802.08385866, ...,
       114260.56556527,  14466.64426984,  23421.96499405])
```

In [54]:
```
model_rf.feature_importances_
feature_importances = pd.DataFrame(model_rf.feature_importances_, index = X_train.columns, columns=['importance']).sort_values('importance', ascending = False)
feature_importances
```

Out[54]:

	importance
engine_size	0.537335
year_model	0.434283
year_of_reference	0.014740
month_of_reference_numeric	0.013642

Métricas de acurácia do modelo

In [55]:
```
mse_randon_forest_sem_parametro = mean_squared_error(Y_test, valores_preditos_rf)
mse_randon_forest_sem_parametro
```

Out[55]:
```
265035291.0246911
```

In [56]:
```
mae_randon_forest_sem_parametro = mean_absolute_error(Y_test, valores_preditos_rf)
mae_randon_forest_sem_parametro
```

Out[56]:
```
8759.807128023971
```

In [57]:
```
r2_randon_forest_sem_parametro = r2_score(Y_test, valores_preditos_rf)
r2_randon_forest_sem_parametro
```

Out[57]:
```
0.9015198997327267
```

In [58]:
```
model_rf_parametros = RandomForestRegressor(max_depth=29, min_samples_leaf=32, min_samples_split=28,
                      n_estimators=208, random_state=43)
```

In [59]:
```
# Ajuste do modelo, de acordo com as variáveis de treinamento
model_rf_parametros.fit(X_train, Y_train)
```

Out[59]:
```
RandomForestRegressor(max_depth=29, min_samples_leaf=32, min_samples_split=28,
                      n_estimators=208, random_state=43)
```

In [60]:
```
# Predição dos valores de salário com base nos dados de teste
valores_preditos_rf_parametros = model_rf_parametros.predict(X_test)
```

In [61]:
```
model_rf_parametros.feature_importances_
feature_importances = pd.DataFrame(model_rf_parametros.feature_importances_, index = X_train.columns, columns=['importance']).sort_values('importance', ascending = False)
feature_importances
```

Out[61]:

	importance
engine_size	0.528769
year_model	0.453227
year_of_reference	0.012909
month_of_reference_numeric	0.005095

In [62]:
```
mse_randon_forest_parametros = mean_squared_error(Y_test, valores_preditos_rf_parametros)
mse_randon_forest_parametros
```

Out[62]:
```
314089299.0892455
```

In [63]:
```
msa_randon_forest_parametros = mean_absolute_error(Y_test, valores_preditos_rf_parametros)
msa_randon_forest_parametros
```

Out[63]:
```
8972.315370303788
```

In [64]:
```
r2_randon_forest_parametros = r2_score(Y_test, valores_preditos_rf_parametros)
r2_randon_forest_parametros
```

Out[64]:
```
0.8832927284981651
```

XGBoost

In [65]:
```
model_xgboost = XGBRegressor()
```

In [66]:
```
# Ajuste do modelo, de acordo com as variáveis de treinamento
model_xgboost.fit(X_train, Y_train)
```

Out[66]:
```
XGBRegressor(base_score=None, booster=None, callbacks=None,
             colsample_bylevel=None, colsample_bynode=None,
             colsample_bytree=None, device=None, early_stopping_rounds=None,
             enable_categorical=False, eval_metric=None, feature_types=None,
             gamma=None, grow_policy=None, importance_type=None,
             interaction_constraints=None, learning_rate=None, max_bin=None,
             max_cat_threshold=None, max_cat_to_onehot=None,
             max_delta_step=None, max_depth=None, max_leaves=None,
             min_child_weight=None, missing=nan, monotone_constraints=None,
```

In [68]:
```
model_xgboost.feature_importances_
feature_importances = pd.DataFrame(model_xgboost.feature_importances_, index = X_train.columns, columns=['importance']).sort_values('importance', ascending = False)
feature_importances
```

Out[68]:

	importance
engine_size	0.542195
year_model	0.417202
year_of_reference	0.032834
month_of_reference_numeric	0.007769

In [69]:
```
mse_xgboost = mean_squared_error(Y_test, valores_preditos_xgboost)
mse_xgboost
```

Out[69]:
```
231894591.46900216
```

In [70]:
```
msa_xgboost = mean_absolute_error(Y_test, valores_preditos_xgboost)
msa_xgboost
```

Out[70]:
```
8403.933034824666
```

In [71]:
```
r2_xgboost = r2_score(Y_test, valores_preditos_xgboost)
r2_xgboost
```

Out[71]:
```
0.9138341066542034
```

In [72]:
```
min(mse_randon_forest_sem_parametro, mse_randon_forest_parametros, mse_xgboost)
```

Out[72]:
```
231894591.46900216
```

In [73]:
```
max(r2_randon_forest_sem_parametro, r2_randon_forest_parametros, r2_xgboost)
```

Out[73]:
```
0.9138341066542034
```

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, $\hat{y}_i$ 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}

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

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

Exercício 1

Questão 5 - Pelos resultados obtidos através da matriz de confusão, olhando na tabela o valor predito e o valor de referência, o algoritmo preditivo Random Forest apresentou menor quantidade de erros na identificação da classe de solo.

Também teve a maior das acurácias, com 92,13% de precisão.

Exercício 2

Questão 7 - Pelo coeficiente de determinação, erro padrão e erro padrão percentual observados dos quatro modelos avaliados, o Random Forest foi o que apresentou melhores resultados. Mas vale a menção que os valores estão bem próximos do modelo de Spurr, logo, também pode ser considerado uma alternativa viável.

COMANDOS

#Instala pacotes necessários

```
install.packages("mlbench")
install.packages("e1071")
install.packages("randomForest")
install.packages("kernlab")
```

```
install.packages("caret")



################################################################################
#####
### Pesquisa com Dados de Satélite (Satellite)
###
################################################################################
#####
#Carrega a bibliotecas
library(mlbench)
library(mice)
library(caret)

##### 1. Carregue a base de dados Satellite
data("Satellite")

# Analisando estrutura
head(Satellite)
str(Satellite)
summary(Satellite)

# Tratando dados
temp_dados <- Satellite[c("x.17","x.18","x.19","x.20","classes")]
set.seed(7)
imp <- mice(temp_dados)
dados <- complete(imp,1)

##### 2. Crie par2ções contendo 80% para treino e 20% para teste
indices <- createDataPartition(dados$classes, p=0.80, list=FALSE)
treino <- Satellite[indices,]
teste <- Satellite[-indices,]

##### 3. Treine modelos RandomForest, SVM e RNA para predição destes dados

#treinando modelos
rf <- train(classes~., data=treino, method="rf")
svm <- train(classes~., data=treino, method="svmRadial")
rna <- train(classes~., data=treino, method="nnet", trace=FALSE)

#Confirmando predição com partição de teste
predicoes.rf <- predict(rf, teste)
predicoes.svm <- predict(svm, teste)
predicoes.rna <- predict(rna, teste)

##### 4. Escolha o melhor modelo com base em suas matrizes de confusão.

confusionMatrix(predicoes.rf, teste$classes)
confusionMatrix(predicoes.svm, teste$classes)
confusionMatrix(predicoes.rna, teste$classes)


################################################################################
#####
### Estimativa de Volumes de Árvores
###
################################################################################
#####
#Carrega a bibliotecas
library(caret)
```

```
# Equação de Spurr Volume = b0 + b1 * dap2 * Ht

##### 1. Carregar o arquivo Volumes.csv

dados <- read.csv("http://www.razer.net.br/datasets/Volumes.csv", sep=";",
dec=",")

# Analisando estrutura
str(dados)
summary(dados)


##### 2. Eliminar a coluna NR, que só apresenta um número sequencial


dados$NR <- NULL
set.seed(7)

##### 3. Criar partição de dados: treinamento 80%, teste 20%

indices <- createDataPartition(dados$VOL, p=0.80, list=FALSE)
treino <- dados[indices,]
teste <- dados[-indices,]


##### 4. Usando o pacote "caret", treinar os modelos: Random Forest (rf),
SVM (svmRadial), Redes
##### Neurais (neuralnet) e o modelo alométrico de SPURR

rf <- caret::train(VOL~., data=treino, method="rf")
svm <- caret::train(VOL~., data=treino, method="svmRadial")
rna <- caret::train(VOL~., data=treino, method="nnet")
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

predicoes.rf <- predict(rf, teste)
predicoes.svm <- predict(svm, teste)
predicoes.rna <- predict(rna, teste)
predicoes.alom <- predict(alom, teste)


##### 6. Crie suas próprias funções (UDF) e calcule as seguintes métricas
entre a predição e os dados
##### observados

R2 <- function(Y_real, Y_pred){
  n = length(Y_pred)
  return ( 1 - ( sum( (Y_real - Y_pred)^2 ) / sum( ( Y_real- mean(Y_real)
)^2 ) ) )
}

Syx <- function(Y_real, Y_pred){
  n = length(Y_pred)
  return  ( sqrt( ((sum( (Y_real - Y_pred)^2  ))  / ( n - 2 ) ) ) )
}

Syxp <- function(Syx, Y_real){
```

```
  return ( Syx / mean(Y_real) * 100 )
}

#Quanto mais perto de 1 melhor é o modelo
R2.rf <- R2(teste$VOL, predicoes.rf)
R2.svm <- R2(teste$VOL, predicoes.svm)
R2.rna <- R2(teste$VOL, predicoes.rna)
R2.alom <- R2(teste$VOL, predicoes.alom)

#Quanto mais perto de 0 melhor
Syx.rf <- Syx(teste$VOL, predicoes.rf)
Syx.svm <- Syx(teste$VOL, predicoes.svm)
Syx.rna <- Syx(teste$VOL, predicoes.rna)
Syx.alom <- Syx(teste$VOL, predicoes.alom)

#Quanto mais perto de 0 melhor
Syxp.rf <- Syxp(Syx.rf, predicoes.rf)
Syxp.svm <- Syxp(Syx.svm, predicoes.svm)
Syxp.rna <- Syxp(Syx.rna, predicoes.rna)
Syxp.alom <- Syxp(Syx.alom, predicoes.alom)
```

Saídas (Análises)

Exercício 1

```
confusionMatrix(predicoes.rf, teste$classes)
Confusion Matrix and Statistics

                     Reference
Prediction            red soil cotton crop grey soil damp grey soil vegetat
ion stubble very damp grey soil
  red soil                 301           0         3              1
7                  0
  cotton crop                0         138         0              1
1                  1
  grey soil                  3           0       263             26
0                  4
  damp grey soil             0           0         3             77
0                 14
  vegetation stubble         2           0         0              0
125                 3
  very damp grey soil        0           2         2             20
8                 279

Overall Statistics

               Accuracy : 0.9213
                 95% CI : (0.9052, 0.9355)
    No Information Rate : 0.2383
    P-Value [Acc > NIR] : < 2.2e-16

                  Kappa : 0.9025

 Mcnemar's Test P-Value : NA

Statistics by Class:

                     Class: red soil Class: cotton crop Class: grey soil Cl
ass: damp grey soil Class: vegetation stubble Class: very damp grey soil
Sensitivity                   0.9837             0.9857          0.9705
0.61600                    0.88652                  0.9269
Specificity                   0.9888             0.9974          0.9674
0.98533                    0.99563                  0.9674
Pos Pred Value                0.9647             0.9787          0.8885
0.81915                    0.96154                  0.8971
```

```
Neg Pred Value               0.9949             0.9983           0.9919
0.95966                   0.98614                  0.9774
Prevalence                   0.2383             0.1090           0.2111
0.09735                   0.10981                  0.2344
Detection Rate               0.2344             0.1075           0.2048
0.05997                   0.09735                  0.2173
Detection Prevalence         0.2430             0.1098           0.2305
0.07321                   0.10125                  0.2422
Balanced Accuracy            0.9862             0.9915           0.9690
0.80067                   0.94108                  0.9472
> confusionMatrix(predicoes.svm, teste$classes)
Confusion Matrix and Statistics

                     Reference
Prediction            red soil cotton crop grey soil damp grey soil vegetat
ion stubble very damp grey soil
  red soil                 303           0         2              0
5                   0
  cotton crop                0         138         2              2
2                   2
  grey soil                  2           0       261             27
0                   7
  damp grey soil             0           1         5             74
1                  21
  vegetation stubble         1           0         0              1
126                 3
  very damp grey soil        0           1         1             21
7                 268

Overall Statistics

               Accuracy : 0.9112
                 95% CI : (0.8943, 0.9262)
    No Information Rate : 0.2383
    P-Value [Acc > NIR] : < 2.2e-16

                  Kappa : 0.8901

 Mcnemar's Test P-Value : NA

Statistics by Class:

                     Class: red soil Class: cotton crop Class: grey soil Cl
ass: damp grey soil Class: vegetation stubble Class: very damp grey soil
Sensitivity                   0.9902             0.9857           0.9631
0.59200                   0.89362                  0.8904
Specificity                   0.9928             0.9930           0.9645
0.97584                   0.99563                  0.9695
Pos Pred Value                0.9774             0.9452           0.8788
0.72549                   0.96183                  0.8993
Neg Pred Value                0.9969             0.9982           0.9899
0.95685                   0.98699                  0.9665
Prevalence                    0.2383             0.1090           0.2111
0.09735                   0.10981                  0.2344

Detection Rate                0.2360             0.1075           0.2033
0.05763                   0.09813                  0.2087
Detection Prevalence          0.2414             0.1137           0.2313
0.07944                   0.10202                  0.2321
Balanced Accuracy             0.9915             0.9894           0.9638
0.78392                   0.94462                  0.9299
> confusionMatrix(predicoes.rna, teste$classes)
Confusion Matrix and Statistics

                     Reference
Prediction            red soil cotton crop grey soil damp grey soil vegetat
ion stubble very damp grey soil
  red soil                 272           3         1              0
2                   0
```

```
  cotton crop               13         136         1             7
95                   2
  grey soil                 20           0        40             5
1                    3
  damp grey soil             0           0         0             0
0                    0
  vegetation stubble         0           0         0             0
1                    0
  very damp grey soil        1           1       229           113
42                 296

Overall Statistics

               Accuracy : 0.5802
                 95% CI : (0.5527, 0.6074)
    No Information Rate : 0.2383
    P-Value [Acc > NIR] : < 2.2e-16

                  Kappa : 0.4692

 Mcnemar's Test P-Value : NA

Statistics by Class:

                     Class: red soil Class: cotton crop Class: grey soil Cl
ass: damp grey soil Class: vegetation stubble Class: very damp grey soil
Sensitivity                   0.8889              0.9714           0.14760
0.00000                0.0070922                   0.9834
Specificity                   0.9939              0.8969           0.97137
1.00000                1.0000000                   0.6073
Pos Pred Value                0.9784              0.5354           0.57971
NaN                    1.0000000                    0.4340
Neg Pred Value                0.9662              0.9961           0.80988
0.90265                0.8908807                   0.9917
Prevalence                    0.2383              0.1090           0.21106
0.09735                0.1098131                   0.2344
Detection Rate                0.2118              0.1059           0.03115
0.00000                0.0007788                   0.2305
Detection Prevalence          0.2165              0.1978           0.05374
0.00000                0.0007788                   0.5312

Balanced Accuracy             0.9414              0.9341           0.55949
0.50000                0.5035461                   0.7954
```

Exercício 2

```
[1] 0.8535647
> Syx.rf
[1] 0.1445527
> Syxp.rf
[1] 10.9554
> R2.svm
[1] 0.8484652
> Syx.svm
[1] 0.1470481
> Syxp.svm
[1] 11.00145
> R2.rna
[1] -0.7244946
> Syx.rna
[1] 0.49606
> Syxp.rna
[1] 49.606
```

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

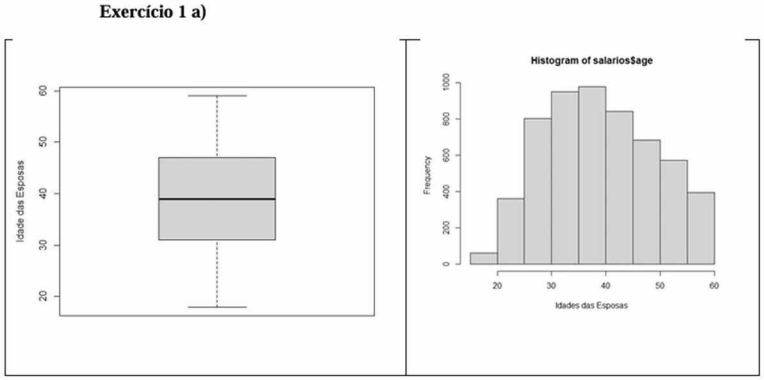

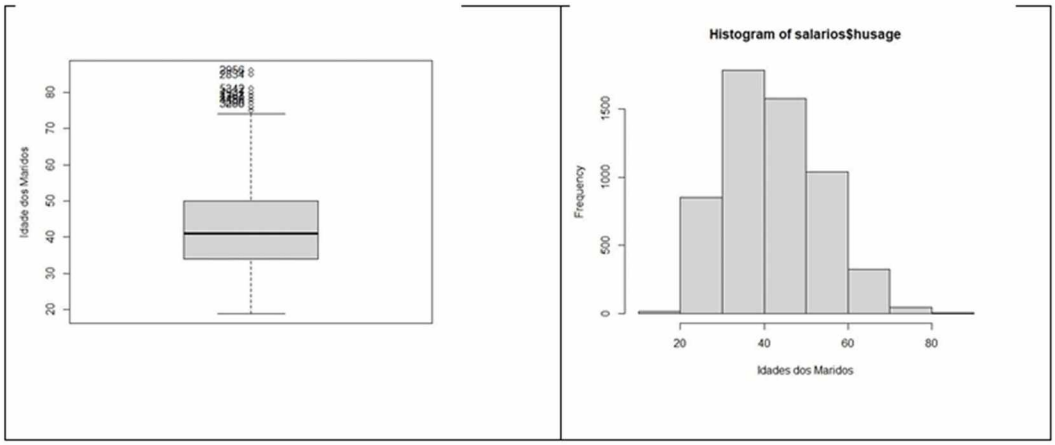

Pelos gráficos podemos entender que os dados das Esposas estão mais distribuídas mas não avançam mais que 60 anos (distância interquartílica está maior nas Esposas pelo gráfico). Os Maridos, por sua vez estão mais concentrados perto da média e tem outliers do gráfico. Chegando a idades de 70 a 80 anos. A distribuição tem curtose à direita.

Exercício 1 b)

Tabela de frequência das idades das Esposas:

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

Tabela de frequência das idades dos Maridos:

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

Pela tabela de frequência vemos a idade das Esposas estarem concentradas no intervalo de maior ou igual a 35,7 e menor que 38,7 anos. Os Maridos se concentram no intervalo maior ou igual a 38,2 e menor que 43,1 anos.

Exercício 2 a)

Para Esposas:

Média: 39,4 anos
Mediana: 39 anos
Moda: 37 anos

Para Maridos

Media: 39 anos
Mediana: 41 anos
Moda: 44 anos

Os dados indicam que a média de idade das esposas é de 39,4 anos, com a mediana sendo 39 anos e a moda 37 anos. Isso sugere que a distribuição de idade das esposas é relativamente simétrica em torno da média, com uma leve concentração de valores em torno dos 37 anos. Corrobora com os gráficos do exercício anterior.

Para os maridos, a média de idade é de 39 anos, mas a mediana é mais alta, 41 anos, e a moda é ainda maior, 44 anos. Essa distribuição sugere uma assimetria, onde há uma concentração de maridos mais velhos, fazendo com que a mediana e a moda se desloquem para idades mais altas em comparação à média.

Fazendo comparação entre as médias 44 /37, temos que a idade dos maridos é 18,92% maior.

Exercício 2 b)

Para Esposas:

Variância: 99,8 anos
Desvio Padrão: 9,98 anos
Coeficiente Variância: 25,33%

Para Maridos:

Variância: 126,0 anos
Desvio Padrão: 11,22 anos
Coeficiente Variância: 26,44%

Para as esposas, os dados mostram uma variância de 99,8 anos e um desvio padrão de 9,98 anos, indicando que as idades estão dispersas em torno da média com essa variação padrão. O coeficiente de variação é de 25,33%, o que sugere uma dispersão moderada das idades em relação à média.

Para os maridos, a variância é de 126,0 anos e o desvio padrão é de 11,22 anos, o que aponta para uma dispersão maior das idades em comparação com as esposas. O coeficiente de variação é de 26,44%, indicando também uma dispersão moderada, mas ligeiramente maior em relação à média do que observado para as esposas. Esses dados ressaltam uma maior heterogeneidade nas idades dos maridos comparado às esposas.

26,38% mais variação de idade nos maridos e também há mais variação. O coeficiente de variação é 1 ponto percentual e alguns décimos maior nos maridos.

Relembrando o gráfico boxplot de ambos comparativamente testamos a hipóteses:

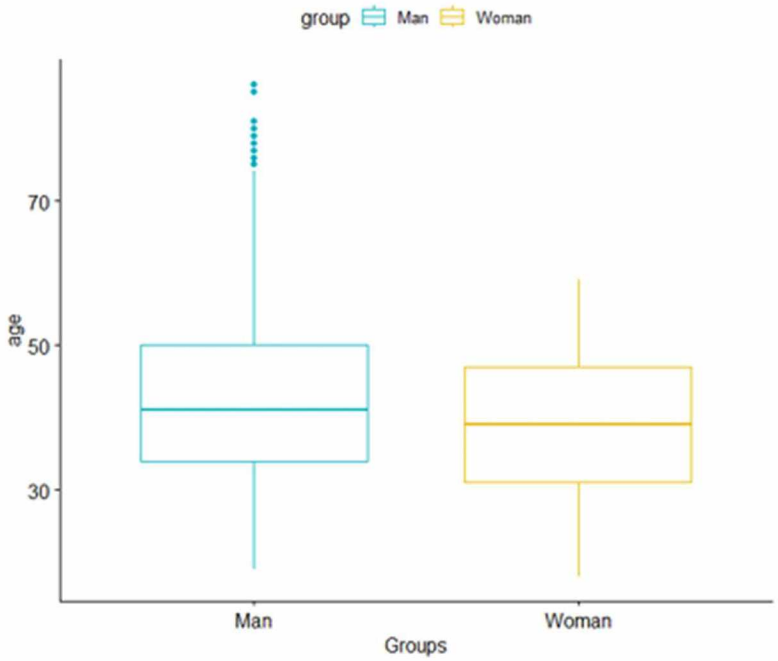

Aplicando o teste:

Wilcoxon rank sum test with continuity correction

data: age by group
W = 18122044, p-value < 0.00000000000000022
alternative hypothesis: true location shift is not equal to 0
95 percent confidence interval:
2.000033 3.000024
sample estimates:
difference in location
2.999966

O teste de soma de postos de Wilcoxon com correção de continuidade mostra que existe uma diferença estatisticamente significativa entre as idades dos dois grupos analisados. O valor de W é 18122044 e o valor de p é extremamente baixo (< 0.00000000000000022), indicando que a diferença observada entre os grupos é muito improvável de ocorrer por acaso.

A hipótese alternativa de que a verdadeira diferença de localização não é igual a zero é suportada. O intervalo de confiança de 95% para a diferença de localização entre os grupos é de aproximadamente 2,00 a 3,00 anos, e a estimativa pontual dessa diferença é de aproximadamente 2,999966 anos. Isso sugere que um dos grupos tende a ter uma idade média significativamente maior que o outro por cerca de 3 anos.

Exercício 3)

Teste de normalidade Esposas:

```
        Lilliefors (Kolmogorov-Smirnov) normality test

data:  salarios$husage
D = 0.059662, p-value < 0.00000000000000022
```

Teste de normalidade Maridos:

```
        Lilliefors (Kolmogorov-Smirnov) normality test

data:  salarios$age
D = 0.058909, p-value < 0.00000000000000022
```

Regra de bolso: Como o p-value não é superior a 0.05, nenhuma das variáveis tem distribuição normal.
Por conseguinte seguiremos para um teste não paramétrico.

Relembrando o gráfico boxplot de ambos comparativamente testamos a hipóteses:

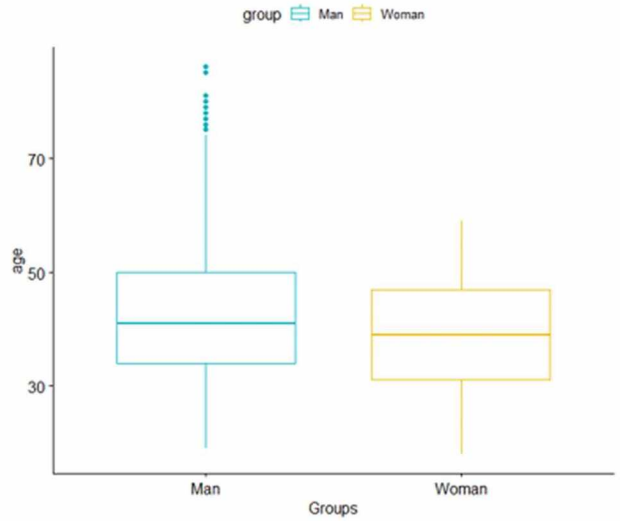

Aplicando o teste:

```
        Wilcoxon rank sum test with continuity correction

data:  age by group
W = 18122044, p-value < 0.00000000000000022
alternative hypothesis: true location shift is not equal to 0
95 percent confidence interval:
 2.000033 3.000024
sample estimates:
difference in location
             2.999966
```

O teste de soma de postos de Wilcoxon com correção de continuidade mostra que existe uma diferença estatisticamente significativa entre as idades dos dois grupos analisados. O valor de W é 18122044 e o valor de p é extremamente baixo (< 0.00000000000000022), indicando que a diferença observada entre os grupos é muito improvável de ocorrer por acaso.

A hipótese alternativa de que a verdadeira diferença de localização não é igual a zero é suportada. O intervalo de confiança de 95% para a diferença de localização entre os grupos é de aproximadamente 2,00 a 3,00 anos, e a estimativa pontual dessa diferença é de aproximadamente 2,999966 anos. Isso sugere que um dos grupos tende a ter uma idade média significativamente maior que o outro por cerca de 3 anos.

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 voçê não precisa aplicar o logaritmo nela para fazer as regressões, mas é necessário aplicar o antilog para obter o resultado da predição.

B – RESOLUÇÃO

Visão geral dos dados carregados

Rows: 2,574
Columns: 17
$ husage <dbl> 56, 31, 33, 34, 42, 45, 33, 31, 31, 44, 45, 22, 66, 43, 26, 37, 51, 38, 37, 54, 29, 35, 38, 44, 31, 40, 33, 34, 53, 25, 26, 53, 3 …
$ husunion <dbl> 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 1, 0, 0, 0, …
$ husearns <dbl> 1500, 800, 950, 1000, 730, 1154, 1350, 769, 340, 750, 1200, 249, 500, 400, 520, 500, 500, 1500, 465, 300, 600, 600, 240, 1450, 67…
$ huseduc <dbl> 14, 17, 13, 14, 14, 16, 16, 18, 12, 12, 12, 12, 16, 12, 14, 12, 12, 16, 12, 18, 16, 16, 18, 18, 16, 18, 12, 18, 12, 11, 15, 17, 1 …
$ husblck <dbl> 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 1, 1, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0, …
$ hushisp <dbl> 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0, …
$ hushrs <dbl> 40, 40, 60, 50, 40, 38, 40, 55, 40, 40, 50, 40, 40, 50, 36, 50, 40, 40, 50, 60, 50, 42, 48, 40, 40, 48, 35, 60, 0, 40, 40, 91, 50 …
$ kidge6 <dbl> 1, 0, 0, 1, 1, 1, 0, 0, 0, 1, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 1, 1, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 1, 1, 0, 0, 1, 0, 1, 0, …
$ earns <dbl> 100, 480, 455, 102, 300, 425, 770, 125, 245, 539, 300, 299, 500, 260, 345, 213, 320, 550, 687, 400, 460, 600, 400, 1100, 4 34, 100…
$ age <dbl> 49, 29, 30, 31, 41, 45, 32, 27, 30, 42, 42, 23, 55, 31, 27, 30, 49, 38, 32, 52, 27, 31, 36, 45, 32, 38, 31, 33, 45, 33, 24, 52, 2…
$ black <dbl> 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 1, 1, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0, …
$ educ <dbl> 12, 14, 12, 12, 12, 18, 12, 14, 15, 12, 12, 13, 12, 12, 14, 12, 12, 16, 17, 18, 14, 12, 16, 18, 14, 18, 12, 18, 12, 10, 12, 18, 1…
$ hispanic <dbl> 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0, …
$ union <dbl> 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 1, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 1, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0, …
$ exper <dbl> 31, 9, 12, 13, 23, 21, 14, 7, 9, 24, 24, 4, 37, 13, 7, 12, 31, 16, 9, 28, 7, 13, 14, 21, 12, 14, 13, 9, 27, 17, 6, 28, 10, 4, 15,…
$ kidlt6 <dbl> 0, 0, 1, 0, 0, 0, 0, 1, 1, 0, 0, 0, 0, 0, 0, 1, 0, 1, 1, 0, 1, 0, 0, 0, 1, 1, 0, 1, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 1, 0, 0, 0, …
$ lwage <dbl> 1.897120, 2.484907, 2.431418, 1.629241, 2.302585, 2.496741, 2.957511, 1.783791, 1.945910, 2.600836, 2.014903, 2.011564, 2.525729

Tamanho dos grupos na separação de 80/20:

Treino
[1] 2059 17

Teste
[1] 515 17

Avaliação pelo modelo de penalidade Ridge

Penalidade: Adiciona uma penalidade do tipo L2 (soma dos quadrados dos coeficientes) ao termo de erro.

Lambda ótimo do modelo Ridge:

0.03162278

Betas das variáveis pelo modelo Ridge

15 x 1 sparse Matrix of class "dgCMatrix"
s0

husage -0.004619353
husearns 0.230244252
huseduc 0.051374229
hushrs -0.069514275
age 0.069223380
educ 0.327075655
husblck 0.217248348
hushisp 0.086154433
kidge6 -0.181933507
black -0.277286478
hispanic -0.011410377
union 0.365674748
kidlt6 -0.042468361
husunion 0.001290081
exper -0.016345064

Betas baixos indicam variáveis menos significativas na explicação da variável independente lwage.

Avaliando o erro quadrático médio e o coeficiente de determinação (R^2):

RMSE Rsquare
1 0.8411446 0.2921319

Resultado: O valor do salário-hora é de 9.422981 dólares, pelo modelo de regressão com penalidade de Ridge. Em relação ao intervalo de confiança temos inferior em 9.401122 dólares e superior em 9.444839 dólares.

Avaliação pelo modelo de penalidade Lasso

Penalidade: Adiciona uma penalidade do tipo L1 (soma dos valores absolutos dos coeficientes) ao termo de erro.

Lambda ótimo do modelo Lasso:

0.01258925

Betas das variáveis pelo modelo Lasso

15 x 1 sparse Matrix of class "dgCMatrix"
s0
husage .
husearns 0.23003841
huseduc 0.03008230
hushrs -0.06025180
age 0.04689039
educ 0.33916643
husblck .
hushisp .
kidge6 -0.14252071
black -0.03169357
hispanic .
union 0.34330221
kidlt6 .
husunion .
exper .

Variáveis com . são não significativas no modelo preditivo.

Avaliando o erro quadrático médio e o coeficiente de determinação (R^2):

```
     RMSE   Rsquare
1 0.8423523 0.2900977
```

Resultado: O valor do salário-hora é de 8.410696 dólares, pelo modelo de regressão com penalidade de Lasso (Least Absolute Shrinkage and Selection Operator). Em relação ao intervalo de confiança temos inferior em 8.388838 dólares e superior em 8.432554 dólares.

Avaliação pelo modelo de penalidade Elastic Net

Penalidade: Combina as penalidades L1 (Lasso) e L2 (Ridge).

Melhor estimativa do modelo para alfa e lambda:

```
     alpha     lambda
7 0.7429763 0.01233549
```

Betas do modelo:

```
15 x 77 sparse Matrix of class "dgCMatrix"
  [[ suppressing 67 column names ‘s0’, ‘s1’, ‘s2’ ... ]]
  [[ suppressing 67 column names ‘s0’, ‘s1’, ‘s2’ ... ]]

husage  . . . . . . . . . . . . .
husearns . . . . 0.005265248 0.02487154 0.04296476 0.05963892 0.0750015
0.08913756 0.1021342 0.1140741 0.1250595 0.1351556
huseduc . . . . . . . . . . . . .
hushrs  . . . . . . . . . . . . .
age     . . . . . . . . . . . . .
educ    . 0.03507813 0.06778955 0.0982384 0.125145010 0.14617055 0.16558804 0.18350187
0.2000085 0.21520547 0.2291845 0.2420330 0.2531897 0.2625779
husblck . . . . . . . . . . . . .

husage  . . . . . . . . . . . . .
husearns 0.1444226 0.1529183 0.1607027 0.1678319 0.173833446 0.179156492 0.1840182380
0.188394337  0.192895375  0.19701293  0.20076870  0.20420169
huseduc . . . . 0.002054596 0.004588311 0.0070671711  0.009692001
0.012130047  0.01426931  0.01627562  0.01810500
hushrs  . . . . . . . -0.003737944 -0.009837325 -0.01541803 -
0.02051807 -0.02518015
age     . . . . . . 0.0009931822  0.006234683  0.010683650
0.01475248  0.01846884  0.02186285
educ    0.2711740 0.2790431 0.2862438 0.2928303 0.297810945 0.302025726 0.3057216471
0.309131551  0.312204359  0.31505880  0.31763223  0.31997957
husblck . . . . . . . . . . . . .

husage  . . . . . . . . . . . . .
husearns 0.20733894  0.21020519  0.21282324  0.21521407  0.21739697  0.21938968  0.22120847
0.22286826  0.22425417  0.22549168  0.22661338
huseduc  0.01977252  0.02129243  0.02267775  0.02394035  0.02509108  0.02613982  0.02709559
0.02796661  0.02880179  0.02942634  0.03008557
hushrs  -0.02944071 -0.03333332 -0.03688891 -0.04013596 -0.04310064 -0.04580704 -0.04827723
-0.05053150 -0.05259683 -0.05448882 -0.05621173
age      0.02496184  0.02779091  0.03037314  0.03272971  0.03488003  0.03684191  0.03863164
0.04026417  0.04173584  0.04307650  0.04429662
educ     0.32212067  0.32407348  0.32585439  0.32747840  0.32895922  0.33030941  0.33154039
0.33266264  0.33364741  0.33462081  0.33545519
husblck  . . . . . . . . . . . .

husage  . . . . . . . . . . . . .
husearns 0.22763557  0.22856772  0.22940155  0.23011730  0.23076951  0.23136351  0.23190493
0.23239844  0.23285117  0.23326236  0.23363590
```

huseduc 0.03068984 0.03124069 0.03186811 0.03263283 0.03339727 0.03409753 0.03473628 0.03531876 0.03575080 0.03623007 0.03667901
hushrs -0.05778305 -0.05921617 -0.06050120 -0.06158733 -0.06257580 -0.06347681 -0.06429821 -0.06504699 -0.06573242 -0.06635490 -0.06692181
age 0.04540920 0.04642363 0.04727635 0.04754591 0.04777970 0.04799196 0.04818484 0.04836014 0.04854642 0.04869006 0.04881966
educ 0.33621383 0.33690521 0.33757363 0.33832341 0.33896436 0.33954668 0.34007726 0.34056075 0.34105880 0.34146336 0.34182488
husblck . . . . . .

husage . . . . . .
husearns 0.23397613 0.234302403 0.23457019 0.23481649 0.23503758 0.23524178 0.23542489 0.23559450 0.23574624 0.23588727 0.23601308
huseduc 0.03708983 0.037639033 0.03815880 0.03862704 0.03906080 0.03945096 0.03981272 0.04013708 0.04043848 0.04070774 0.04095866
hushrs -0.06743847 -0.067899109 -0.06831098 -0.06868668 -0.06902866 -0.06934063 -0.06962457 -0.06988364 -0.07011939 -0.07033455 -0.07053028
age 0.04893746 0.049016780 0.04910094 0.04917805 0.04924724 0.04931099 0.04936814 0.04942096 0.04946823 0.04951205 0.04955117
educ 0.34215342 0.342352008 0.34251725 0.34267117 0.34280687 0.34293384 0.34304554 0.34315074 0.34324284 0.34333025 0.34340631
husblck . 0.007295743 0.03634675 0.06238293 0.08708525 0.10887744 0.12959437 0.14773539 0.16506953 0.18012347 0.19460069

husage . . -0.0002716424 -0.002158684 -0.00358911 -0.00471071 -0.005783262 -0.006661823 .....
husearns 0.23613051 0.23623490 0.2363815821 0.236542564 0.23667499 0.23679976 0.236911010 0.237016057 .....
huseduc 0.04118170 0.04139039 0.0415540236 0.041691684 0.04181624 0.04192557 0.042029550 0.042116924 .....
hushrs -0.07070898 -0.07087150 -0.0710544985 -0.071224076 -0.07137585 -0.07151563 -0.071642336 -0.071758936 .....
age 0.04958759 0.04962000 0.0498831915 0.051553402 0.05282458 0.05382458 0.054779523 0.055564264 .....
educ 0.34347922 0.34354216 0.3436012153 0.343647277 0.34369778 0.34374575 0.343786969 0.343828708 .....
husblck 0.20704468 0.21910724 0.2293417339 0.239228152 0.24848356 0.25603883 0.263460313 0.269436473 .....

.....
.....suppressing 10 columns and 1 rows in show(); maybe adjust 'options(max.print= *, width = *)'
.....
[[suppressing 67 column names ‘s0’, ‘s1’, ‘s2’ ...]]

kidge6 . . . . . -0.007067256 -0.02156613
black . . . . . .
hispanic . . . . . .
union 0.01387615 0.04486632 0.07331676 0.09941872 0.123352 0.1452849 0.1656124 0.1843023 0.201429528 0.21622602
kidlt6 . . . . . .
husunion . . . . . .
exper . . . . . .

kidge6 -0.03467388 -0.04665826 -0.05762127 -0.06764355 -0.07680314 -0.08517209 -0.09281679 -0.09979837 -0.1061731 -0.1119926 -0.1173043 -0.1221519
black . . . . . .
hispanic . . . . . .
union 0.22983826 0.24227059 0.25364022 0.26402875 0.27351847 0.28218523 0.29009879 0.29732326 0.3039175 0.3099356 0.3154272 0.3204375

kidlt6 . . . . . .
husunion . . . . . .
exper . . . . . .

kidge6 -0.126561536 -0.1305701 -0.13423334 -0.13757501 -0.14062286 -0.1435986917 -0.147494967 -0.151076430 -0.15434390 -0.15732421 -0.16004235
black -0.005668806 -0.0125087 -0.01874408 -0.02443129 -0.02961807 -0.0341888440 -0.037914789 -0.041305121 -0.04439560 -0.04721274 -0.04978062
hispanic . . . . . .
union 0.325287423 0.3297732 0.33387756 0.33762152 0.34103604 0.3440766596 0.346741136 0.349181234 0.35140640 0.35343511 0.35528459
kidlt6 . . . . . -0.0005768108 -0.004429082 -0.007967649 -0.01119672 -0.01414263 -0.01682990
husunion . . . . . .
exper . . . . . .

kidge6 -0.16244906 -0.16471269 -0.16677956 -0.16866426 -0.17047047 -0.17207870 -0.17354382 -0.17488091 -0.17609849 -0.17720968 -0.17822126
black -0.05213580 -0.05426880 -0.05621205 -0.05798308 -0.06650679 -0.09563775 -0.12177377 -0.14652834 -0.16840565 -0.18916520 -0.20738180
hispanic . . . . . .
union 0.35695564 0.35849197 0.35989405 0.36117226 0.36230063 0.36316725 0.36395958 0.36467629 0.36533379 0.36592821 0.36647429
kidlt6 -0.01921953 -0.02145752 -0.02350105 -0.02536472 -0.02712410 -0.02867070 -0.03007995 -0.03136525 -0.03253623 -0.03360417 -0.03457696
husunion . . . . . .
exper . . . . . .

kidge6 -0.17914455 -0.1799848 -0.18075183 -0.18144961 -0.18208675 -0.18266039 -0.18322243 -0.18373148 -0.18418786 -0.18460658 -0.18498279 .....
black -0.22475129 -0.2398732 -0.25438012 -0.26688641 -0.27897455 -0.28925476 -0.29913493 -0.30837523 -0.31596059 -0.32338481 -0.32940138 .....
hispanic . . . .
union 0.36696743 0.3674212 0.36783037 0.36820759 0.36854727 0.36885728 0.36911340 0.36934646 0.36956744 0.36976486 0.36995081 .....
kidlt6 -0.03546417 -0.0362722 -0.03700918 -0.03768022 -0.03829234 -0.03886517 -0.03958127 -0.04020237 -0.04074453 -0.04124557 -0.04168828 .....
husunion . . . .
exper . . . .

Avaliando o erro quadrático médio e o coeficiente de determinação (R^2):
RMSE Rsquare
1 0.8419627 0.2907543

Resultado: O valor do salário-hora é de 8.003162 dólares, pelo modelo de regressão com penalidade de Elastic Net. Em relação ao intervalo de confiança temos inferior em é 7.981303 dólares e superior em 8.02502 dólares.

Conclusão

Avaliando os modelos pelo menor erro quadrático médio e/ou maior coeficiente, temos:
Model RMSE R_square
1 Ridge 0.9893314 0.2590861
2 Lasso 0.9899393 0.2581753
3 Elastic Net 0.9893725 0.2590245
Logo o modelo de regressão linear com penalidade escolhido foi o Ridge.
CODIGO:

Instalar os pacotes necessários

```
if(!require('plyr')) {
```

```
  install.packages('plyr')
  library('plyr')
}

if(!require('readr')) {
  install.packages('readr')
  library('readr')
}

if(!require('dplyr')) {
  install.packages('dplyr')
  library('dplyr')
}

if(!require('caret')) {
  install.packages('caret')
  library('caret')
}

if(!require('ggplot2')) {
  install.packages('ggplot2')
  library('ggplot2')
}

if(!require('repr')) {
  install.packages('repr')
  library('repr')
}

if(!require('ggplot2')) {
  install.packages('ggplot2')
  library('glmnet')
}



# Carregar o conjunto de dados
#setwd('') #se necessário apontar para onde descompactou
load("trabalhosalarios.RData")


# Guardar o conjunto de dados em um objeto
data <- trabalhosalarios

# Ver o conjunto de dados inteiro
View(data)

# Visualizar parte do conjunto de dados
glimpse(data)

set.seed(302)

# Criar um índice para particionar o conjunto de dados em 80% para
treinamento
index <- sample(1:nrow(data), 0.8 * nrow(data))

# Criar o conjunto de dados de treinamento
train <- data[index,]

# Criar o conjunto de dados de teste
test <- data[-index,]
```

```
# Checar as dimensões dos conjuntos de treinamento e teste
dim(train)
dim(test)

# Padronizar as variáveis
# Criar um objeto com as variáveis a serem padronizadas
# Variáveis binárias não são padronizadas
cols <- c('husage', 'husearns', 'huseduc', 'hushrs',
          'age', 'educ', 'lwage', 'exper')

# Padronizar o conjunto de dados 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])

# Ver o resumo estatístico das variáveis padronizadas de cada conjunto de
dados
summary(train)
summary(test)

#############################################################
#                      REGRESSÃO RIDGE                      #
#############################################################
# Estimar o salário-hora da esposa (lwage)

# Criar um objeto com as variáveis que serão usadas no modelo
cols_reg <- c('husage', 'husearns', 'huseduc', 'hushrs',
              'age', 'educ', 'lwage','husblck',
              'hushisp', 'kidge6', 'black', 'hispanic',
              'union', 'kidlt6', 'husunion', 'exper')

# Gerar variáveis dummies para organizar os conjuntos de dados em objetos
tipo matriz
dummies <- dummyVars(lwage ~ husage + husearns + huseduc + hushrs +
                       age + educ + husblck + hushisp +
                       kidge6 + black + hispanic + union + kidlt6 +
husunion + exper,
                     data = data[,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))

# Guardar a matriz de dados de treinamento das variáveis explicativas para
o modelo
x <- as.matrix(train_dummies)

# Guardar o vetor de dados de treinamento da variável dependente para o
modelo
y_train <- train$lwage

# Guardar a matriz de dados de teste das variáveis explicativas para o
modelo
x_test <- as.matrix(test_dummies)

# Guardar o vetor de dados de teste da variável dependente para o modelo
y_test <- test$lwage

# Calcular o valor ótimo de lambda
# alpha = "0", é para regressão Ridge
```

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

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

# Ver qual o lambda ótimo
best_lambda_ridge <- ridge_lamb$lambda.min
best_lambda_ridge

# Estimar o modelo Ridge
ridge_reg <- glmnet(x, y_train, nlambda = 25, alpha = 0,
                    family = 'gaussian',
                    lambda = best_lambda_ridge)
# Ver o resultado (valores) da estimativa (coeficientes)
ridge_reg[["beta"]]

# Calcular o R^2 dos valores verdadeiros e preditos
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 métricas de performance do modelo:
  data.frame(
    RMSE = RMSE,
    Rsquare = R_square
  )
}

# Predição e avaliação nos dados de treinamento
predictions_train <- predict(ridge_reg,
                             s = best_lambda_ridge,
                             newx = x)

# As métricas do conjunto de treinamento
eval_results(y_train, predictions_train, train)

# Predição e avaliação nos dados de teste
predictions_test <- predict(ridge_reg,
                            s = best_lambda_ridge,
                            newx = x_test)

# As métricas do conjunto de teste
eval_ridge <- eval_results(y_test, predictions_test, test)


# Fazer uma predição

# husage = 40 anos (idade do marido)
husage = (40-pre_proc_val[["mean"]][["husage"]])/
  pre_proc_val[["std"]][["husage"]]

# 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 não é hispânico)
hushisp = 0

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

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

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

# black = 0 (esposa não 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 hispânica)
hispanic = 1

# union = 0 (o casal não possui união registrada)
union = 0

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

# husunion = 0 (marido não possui união estável)
husunion = 0

# exper = 18 (anos de experiência de trabalho da esposa)
exper = (18-pre_proc_val[["mean"]][["exper"]])/
  pre_proc_val[["std"]][["exper"]]

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

predict_our_ridge <- predict(ridge_reg,
                             s = best_lambda_ridge,
```

```
                              newx = our_pred)

# O resultado da predição:
predict_our_ridge

# Convertê-lo para o valor nominal, consistente com o conjunto de dados
original
pred_ridge <- (predict_our_ridge *
                       pre_proc_val[["std"]][["lwage"]]) +
  pre_proc_val[["mean"]][["lwage"]]


# Antilog
pred_ridge <- exp(pred_ridge)

# O resultado é:
pred_ridge


# O intervalo de confiança para o nosso exemplo é:
n <- nrow(train) # tamanho da amostra
m <- pred_ridge # valor médio predito
s <- pre_proc_val[["std"]][["lwage"]] # desvio padrão
dam <- s/sqrt(n) # distribuição da amostragem da média
CIlwr_ridge <- m + (qnorm(0.025))*dam # intervalo inferior
CIupr_ridge <- m - (qnorm(0.025))*dam # intervalo superior

# Os valores são:
CIlwr_ridge
CIupr_ridge


# O valor salário-hora é de 9.422981 dólares.
# O valor mínimo do salário-hora é 9.401122 dólares.
# O valor máximo do salário-hora é 9.444839 dólares.


#################################################################
#                        REGRESSAO LASSO                        #
#################################################################
# Estimar o salário-hora da esposa (lwage)

# Criar um objeto com as variáveis que usaremos no modelo
cols_reg <- c('husage', 'husearns', 'huseduc', 'hushrs',
              'age', 'educ', 'lwage','husblck',
              'hushisp', 'kidge6', 'black', 'hispanic',
              'union', 'kidlt6', 'husunion', 'exper')

# Gerar variáveis dummies para organizar os conjuntos de dados em objetos
tipo matriz
dummies <- dummyVars(lwage ~ husage + husearns + huseduc + hushrs +
                       age + educ + husblck + hushisp +
                       kidge6 + black + hispanic + union + kidlt6 +
husunion + exper,
                     data = data[,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))
```

```
# Guardar a matriz de dados de treinamento das variáveis explicativas para
o modelo
x <- as.matrix(train_dummies)

# Guardar o vetor de dados de treinamento da variável dependente para o
modelo
y_train <- train$lwage

# Guardar a matriz de dados de teste das variáveis explicativas para o
modelo
x_test <- as.matrix(test_dummies)

# Guardar o vetor de dados de teste da variável dependente para o modelo
y_test <- test$lwage

# Calcular o valor ótimo de lambda
# Atribuir alpha = 1 para implementar a regressão Lasso
# Testar os lambdas de 10^-3 até 10^2, a cada 0.1
lambdas <- 10^seq(2, -3, by = -0.1)

# Calcular o lambda
lasso_lamb <- cv.glmnet(x, y_train, alpha = 1,
                        lambda = lambdas,
                        standardize = TRUE, nfolds = 5)

# Guardar o lambda "ótimo"
best_lambda_lasso <- lasso_lamb$lambda.min
best_lambda_lasso


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

# Visualizar os coeficientes estimados
lasso_model[["beta"]]

# Fazer as predições na base de treinamento e avaliar a regressão Lasso
predictions_train <- predict(lasso_model,
                             s = best_lambda_lasso,
                             newx = x)

# Calcular o R^2 dos valores verdadeiros e preditos
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 métricas de performance do modelo:
  data.frame(
    RMSE = RMSE,
    Rsquare = R_square
  )
}

# As métricas da base de treinamento são:
eval_results(y_train, predictions_train, train)

# Fazer as predições na base de teste
```

```
predictions_test <- predict(lasso_model,
                            s = best_lambda_lasso,
                            newx = x_test)

# As métricas da base de teste são:
eval_lasso <- eval_results(y_test, predictions_test, test)

# Fazer uma predição

# husage = 40 anos (idade do marido)
husage = (40 - pre_proc_val[["mean"]][["husage"]]) /
  pre_proc_val[["std"]][["husage"]]

# 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 não é hispânico)
hushisp = 0

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

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

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

# black = 0 (esposa não 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 hispânica)
hispanic = 1

# union = 0 (o casal não possui união registrada)
union = 0

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

# husunion = 0 (marido não possui união estável)
husunion = 0

# exper = 18 (anos de experiência de trabalho da esposa)
exper = (18 - pre_proc_val[["mean"]][["exper"]]) /
  pre_proc_val[["std"]][["exper"]]
```

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

predict_our_lasso <- predict(lasso_model,
                             s = best_lambda_lasso,
                             newx = our_pred)
predict_our_lasso

# Convertê-lo para valor compatível com o dataset original
pred_lasso <- (predict_our_lasso *
                      pre_proc_val[["std"]][["lwage"]]) +
  pre_proc_val[["mean"]][["lwage"]]


# Antilog
pred_lasso <- exp(pred_lasso)

# O resultado é:
pred_lasso

# Criar o intervalo de confiança
n <- nrow(train)
m <- pred_lasso
s <- pre_proc_val[["std"]][["lwage"]]
dam <- s/sqrt(n)
CIlwr_lasso <- m + (qnorm(0.025))*dam
CIupr_lasso <- m - (qnorm(0.025))*dam

# O intervalo de confiança é:
CIlwr_lasso
CIupr_lasso


# O valor salário-hora é de 8.410696 dólares.
# O valor mínimo do salário-hora é 8.388838 dólares.
# O valor máximo do salário-hora é 8.432554 dólares.


#############################################################
#                      REGRESSAO ELASTICNET                 #
#############################################################
# Estimar o salário-hora da esposa (lwage)

# Criar um objeto com as variáveis que usaremos no modelo
cols_reg <- c('husage', 'husearns', 'huseduc', 'hushrs',
              'age', 'educ', 'lwage','husblck',
              'hushisp', 'kidge6', 'black', 'hispanic',
```

```
              'union', 'kidlt6', 'husunion', 'exper')

# Gerar variáveis dummies para organizar os conjuntos de dados em objetos
tipo matriz
dummies <- dummyVars(lwage ~ husage + husearns + huseduc + hushrs +
                       age + educ + husblck + hushisp +
                       kidge6 + black + hispanic + union + kidlt6 +
husunion + exper,
                     data = data[,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))


# Guardar a matriz de dados de treinamento das variáveis explicativas para
o modelo
x <- as.matrix(train_dummies)

# Guardar o vetor de dados de treinamento da variável dependente para o
modelo
y_train <- train$lwage

# Guardar a matriz de dados de teste das variáveis explicativas para o
modelo
x_test <- as.matrix(test_dummies)

# Guardar o vetor de dados de teste da variável dependente para o modelo
y_test <- test$lwage


# Configurar o treinamento do modelo por cross validation, com 10 folders,
5 repetições e busca aleatória dos componentes das amostras de treinamento
train_cont <- trainControl(method = "repeatedcv",
                           number = 10,
                           repeats = 5,
                           search = "random",
                           verboseIter = TRUE)

# Treinar o modelo
elastic_reg <- train(lwage ~ husage + husearns + huseduc + hushrs +
                       age + educ + husblck + hushisp +
                       kidge6 + black + hispanic + union + kidlt6 +
husunion + exper,
                     data = train,
                     method = "glmnet",
                     tuneLength = 10,
                     trControl = train_cont)

# O melhor parâmetro alpha escolhido é:
elastic_reg$bestTune

# Os coeficientes do modelo são:
elastic_reg[["finalModel"]][["beta"]]


predictions_train <- predict(elastic_reg, x)

# Calcular o R^2 dos valores verdadeiros e preditos
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 métricas de performance do modelo:
  data.frame(
    RMSE = RMSE,
    Rsquare = R_square
  )
}

# As métricas de performance na base de treinamento são:
eval_results(y_train, predictions_train, train)

# Fazer as predições na base de teste
predictions_test <- predict(elastic_reg, x_test)

# As métricas de performance na base de teste são:
eval_elastic <- eval_results(y_test, predictions_test, test)

# Fazer uma predição

# husage = 40 anos (idade do marido)
husage <- (40 - pre_proc_val[["mean"]][["husage"]]) /
  pre_proc_val[["std"]][["husage"]]

# 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 não é hispânico)
hushisp <- 0

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

# kidge6 = 1 (tem filhos maiores de 6 anos)
kidge6 <- 1

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

# black = 0 (esposa não 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 hispânica)
hispanic <- 1

# union = 0 (o casal não possui união registrada)
```

```
union <- 0

# kidlt6 = 1 (possui filhos com menos de 6 anos)
kidlt6 <- 1

# husunion = 0 (marido não possui união estável)
husunion <- 0

# exper = 18 (anos de experiência de trabalho da esposa)
exper <- (18 - pre_proc_val[["mean"]][["exper"]]) /
  pre_proc_val[["std"]][["exper"]]

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

predict_our_elastic <- predict(elastic_reg, our_pred)
predict_our_elastic

# Converter para o nível dos valores originais do dataset
pred_elastic <- (predict_our_elastic *
                         pre_proc_val[["std"]][["lwage"]]) +
  pre_proc_val[["mean"]][["lwage"]]


# Antilog
pred_elastic <- exp(pred_elastic)

# O resultado é:
pred_elastic


# Criar o intervalo de confiança
n <- nrow(train)
m <- pred_elastic
s <- pre_proc_val[["std"]][["lwage"]]
dam <- s / sqrt(n)
CIlwr_elastic <- m + (qnorm(0.025)) * dam
CIupr_elastic <- m - (qnorm(0.025)) * dam

# Os valores mínimo e máximo são:
CIlwr_elastic
CIupr_elastic

# O valor salário-hora é de 8.003162 dólares.
# O valor mínimo do salário-hora é 7.981303 dólares.
# O valor máximo do salário-hora é 8.02502 dólares.
```

```
# Combinar os resultados (RMSE e R²)
results <- data.frame(
  Model = c("Ridge", "Lasso", "Elastic Net"),
  RMSE = c(eval_ridge$RMSE, eval_lasso$RMSE, eval_elastic$RMSE),
  R_square = c(eval_ridge$Rsquare, eval_lasso$Rsquare,
eval_elastic$Rsquare)
)

# Escolher o modelo com o menor RMSE e/ou o maior R²
best_model <- results[which.min(results$RMSE), ]

# Mostrar a tabela de resultados
print(results)

# Mostrar o melhor modelo
print(best_model)


# Combinar os resultados min, max e salario-hora
results_lwage <- data.frame(
  Model = c("Ridge", "Lasso", "Elastic Net"),
  min = c(CIlwr_ridge, CIlwr_lasso, CIlwr_elastic),
  max = c(CIupr_ridge, CIupr_lasso, CIupr_elastic),
  lwage = c(pred_ridge, pred_lasso,pred_elastic)
)

# Mostrar a tabela de resultados
print(results_lwage)
```

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

Item 1 - Identificador de idiomas

Problema: Dados um texto de entrada, é possível identificar em qual língua o texto está escrito?

Entrada: "texto qualquer"
Saída: português ou inglês ou espanhol

A) O processo de Reconhecimento de Padrões

O objetivo desse trabalho é demonstrar o processo de "construção de atributos" e como ele é fundamental para o **Reconhecimento de Padrões (RP)**.

Primeiro um conjunto de "amostras" previamente conhecido (classificado)

[262]
```
#
# amostras de texto em diferentes línguas
#
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.",
]
```

Transformando amostras em **padrões**

```
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)
print(pre_padroes)
```

```
[['How was your weekend?', 'inglês'], ['Meu time de futebol favorito ganhou o jogo.', 'português'], ['O livro que estou lendo é muito interessante.', 'português'], ['Estoy estudiando para mis exámenes.', 'espanhol'], ['This is a beautiful place.', 'inglês'], ['¿C
```

Visualizando os dados em um DataFrame

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

	0	1
0	How was your weekend?	inglês
1	Meu time de futebol favorito ganhou o jogo.	português
2	O livro que estou lendo é muito interessante.	português
3	Estoy estudiando para mis exámenes.	espanhol
4	This is a beautiful place.	inglês
...	...	...
87	Voy al parque todos los días.	espanhol
88	Do you have any recommendations for restaurants?	inglês
89	¿Tienes alguna recomendación de restaurantes?	espanhol
90	Vamos fazer um churrasco no final de semana.	português
91	I enjoy going to the beach.	inglês

92 rows × 2 columns

Próximas etapas: Gerar código com dados | Ver gráficos recomendados

B) Construção dos atributos

```
# a entrada é o vetor pre_padroes e a saída desse passo deverá ser "padrões"
import re

def tamanhoMedioFrases(texto):
  palavras = re.split("\s",texto)
  #print(palavras)
  tamanhos = [len(s) for s in palavras if len(s)>0]
  #print(tamanhos)
  soma = 0
  for t in tamanhos:
    soma=soma+t
  return soma / len(tamanhos)

def contaPalavras(texto, palavras_comuns):
    contagem = 0
    for palavra in palavras_comuns:
        contagem += texto.lower().split().count(palavra)
        #print(contagem)
    return contagem

# Função: detectaComuns
# Dectar a frequência de palavras (artigos, preposições,
# contrações etc) mais frequentes em frases destes idiomas

def detectaComuns(texto):

  cont_pt = 0
  cont_en = 0
  cont_es = 0

  palavras_comuns_pt = [
        'de', 'a', 'o', 'que', 'e', 'do', 'da', 'em', 'um', 'para',
        'é', 'com', 'não', 'uma', 'os', 'no', 'se', 'na', 'por', 'mais'
    ]
  palavras_comuns_en = [ 'the', 'be', 'to', 'of', 'and', 'a', 'in', 'that', 'have', 'I',
        'it', 'for', 'not', 'on', 'with', 'he', 'as', 'you', 'do', 'at' ]
  palavras_comuns_es =  [
        'de', 'la', 'que', 'el', 'en', 'y', 'a', 'los', 'se', 'del',
        'las', 'por', 'un', 'para', 'con', 'no', 'una', 'su', 'al', 'lo'
    ]

  cont_pt = contaPalavras(texto,palavras_comuns_pt)
  cont_en = contaPalavras(texto,palavras_comuns_en)
  cont_es = contaPalavras(texto,palavras_comuns_es)

  if cont_pt > cont_en and cont_pt > cont_es:
      return 1  # Português
  elif cont_en > cont_pt and cont_en > cont_es:
      return 2  # Inglês
  elif cont_es > cont_pt and cont_es > cont_en:
      return 3  # Espanhol
  else:
      return 0  # Indeterminado


# Função: detectaDigrafos
# Dectar a frequência de dígrafos

def contaDigrafos(texto, digrafos):
    soma_total = 0
    for digrafo in digrafos:
        ocorrencias = texto.count(digrafo)
        soma_total += ocorrencias
    return soma_total
```

```python
def detectaDigrafos(texto):

  cont_pt = 0
  cont_en = 0
  cont_es = 0

  digrafos_ingles = ["th", "sh", "ch", "ph", "wh", "ck"]
  digrafos_espanhol = ["ll", "ch", "rr", "qu", "gu"]
  digrafos_portugues = ["ch", "lh", "nh", "ss", "rr", "qu", "gu"]

  cont_pt = contaDigrafos(texto,digrafos_portugues)
  cont_es = contaDigrafos(texto,digrafos_espanhol)
  cont_en = contaDigrafos(texto,digrafos_ingles)

  if cont_pt > cont_en and cont_pt > cont_es:
      return 1  # Português
  elif cont_en > cont_pt and cont_en > cont_es:
      return 2  # Inglês
  elif cont_es > cont_pt and cont_es > cont_en:
      return 3  # Espanhol
  else:
      return 0  # Indeterminado


def extraiCaracteristicas(frase):
  # frase é um vetor [ 'texto', 'lingua' ]
  texto = frase[0]
  pattern_regex = re.compile('[^\w+]', re.UNICODE)
  texto = re.sub(pattern_regex,' ',texto)
  #print(texto)
  caracteristica1=tamanhoMedioFrases(texto)
  caracteristica2=detectaComuns(texto)
  caracteristica3=detectaDigrafos(texto)
  # acrescente as suas funcoes no vetor padrao
  padrao = [caracteristica1, caracteristica2, caracteristica3, frase[1] ]
  return padrao


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

# converte o formato [frase classe] em
# [caracteristica_1, caracteristica_2,... caracteristica n, classe]
padroes = geraPadroes(pre_padroes)

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

	0	1	2	3
0	4.250000	0	0	inglês
1	4.375000	1	1	português
2	4.625000	1	1	português
3	6.000000	0	0	espanhol
4	4.200000	0	0	inglês
...	...	...	...	...
87	3.833333	3	0	espanhol
88	5.857143	2	0	inglês
89	7.800000	0	0	espanhol
90	4.500000	1	0	português
91	3.500000	2	2	inglês

92 rows × 4 columns

C) Treinando o modelo com SVM

Separando o conjunto de treinamento do conjunto de testes

```
from sklearn.model_selection import train_test_split
import numpy as np


#from sklearn.metrics import confusion_matrix

vet = np.array(padroes)
classes = vet[:,-1]         # classes = [p[-1] for p in padroes]
#print(classes)
padroes_sem_classe = vet[:,0:-1]
#print(padroes_sem_classe)
X_train, X_test, y_train, y_test = train_test_split(padroes_sem_classe, classes, test_size=0.25, stratify=classes)
```

Com os conjuntos separados, podemos "treinar" o modelo usando a SVM.

```
from sklearn import svm
from sklearn.metrics import confusion_matrix
from sklearn.metrics import classification_report

treinador = svm.SVC()  #algoritmo escolhido
modelo = treinador.fit(X_train, y_train)

#
# score com os dados de treinamento
acuracia = modelo.score(X_train, y_train)
print("Acurácia nos dados de treinamento: {:.2f}%".format(acuracia * 100))

#
# melhor avaliar com a matriz de confusão
y_pred = modelo.predict(X_train)
cm = confusion_matrix(y_train, y_pred)
print(cm)
print(classification_report(y_train, y_pred))

#
# com dados de teste que não foram usados no treinamento
print('métricas mais confiáveis')
y_pred2 = modelo.predict(X_test)
cm = confusion_matrix(y_test, y_pred2)
print(cm)
print(classification_report(y_test, y_pred2))
```

```
Acurácia nos dados de treinamento: 81.16%
[[14  0  8]
 [ 1 19  3]
 [ 1  0 23]]
              precision    recall  f1-score   support

    espanhol       0.88      0.64      0.74        22
      inglês       1.00      0.83      0.90        23
   português       0.68      0.96      0.79        24

    accuracy                           0.81        69
   macro avg       0.85      0.81      0.81        69
weighted avg       0.85      0.81      0.81        69

métricas mais confiáveis
[[6 0 2]
 [0 3 4]
 [0 0 8]]
              precision    recall  f1-score   support

    espanhol       1.00      0.75      0.86         8
      inglês       1.00      0.43      0.60         7
   português       0.57      1.00      0.73         8


    accuracy                           0.74        23
   macro avg       0.86      0.73      0.73        23
weighted avg       0.85      0.74      0.73        23
```

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

Seed utilizado: 202475
(Ano atual com 4 dígitos + 2 algarismos do dígito verificador do CPF de um
dos integrantes)

Especificações:
O trabalho pode ser feito por uma equipe de 1 a 6 integrantes.
Para cada problema, preencher as colunas dos quadros com o que pede.
Além disso, fazer as solicitações pedidas antes dos quadros.

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

Predição de novos casos:

	Comp	Circ	DCirc	RadRa	PrAxisRa	MaxLRa	ScatRa	Elong	PrAxisRect	MaxLRect	ScVarMaxis	ScVarmaxis	RaGyr	SkewMaxis	Skewmaxis	Kurtmaxis	KurtMaxis	HollRa	predict.rna
1	98	53	87	181	78	11	165	43	23	165	177	381	189	75	7	18	189	198	van
2	89	37	72	156	45	7	146	42	16	139	165	325	151	67	8	12	181	197	saab
3	106	58	89	210	87	12	211	36	28	155	219	648	185	76	7	7	186	193	bus

Técnica	Parâmetro	Acurácia	Matriz de Confusão
RNA – CV	size=21, decay=0.4	0.8443	
RF – Hold-out	mtry=10	0.7725	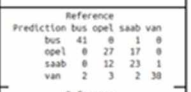
RF – CV	mtry=10	0.7665	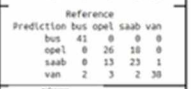
SVM – CV	C=1, Sigma= 0.07587065	0.7425	
SVM – Hold-out	C=1, Sigma= 0.07587065	0.7425	
RNA – Hold-out	size=5, decay=0.1	0.6347	
KNN	k=1	0.6294	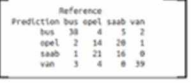

Lista de Comandos:

```
########################### RNA - CV
### Instalação dos pacotes necessários
#install.packages("e1071")
#install.packages("caret")
#install.packages("mlbench")
#install.packages("mice")
library(mlbench)
library("caret")

## Leitura dos dados
dados <- read.csv("6 - Veiculos - Dados.csv")


### Retira o atributo a
dados$a <- NULL
View(dados)


### Cria um arquivo com treino com 80% e teste com 20% das linhas de forma randomizada
set.seed(202475)
indices <- createDataPartition(dados$tipo, p=0.80,list=FALSE)
treino <- dados[indices,]
teste <- dados[-indices,]

### indica o método cv e numero de folders 10
ctrl <- trainControl(method = "cv", number = 10)

### executa a RNA com esse ctrl
set.seed(202475)
rna <- train(tipo~., data=treino, method="nnet",trace=FALSE, trControl=ctrl)
predict.rna <- predict(rna, teste)
confusionMatrix(predict.rna, as.factor(teste$tipo))
```

```
#parametrização da RNA
### size, decay
grid <- expand.grid(size = seq(from = 1, to = 35, by = 10), decay = seq(from = 0.1, to = 0.6, by = 0.3))
set.seed(202475)
rna <- train(
  form = tipo~. ,
  data = treino ,
  method = "nnet" ,
  tuneGrid = grid ,
  trControl = ctrl ,
  maxit = 2000,trace=FALSE)
```

```
# Exibir o modelo treinado
rna


### Faz as predições e mostra matriz de confusão
predict.rna <- predict(rna, teste)
confusionMatrix(predict.rna, as.factor(teste$tipo))


### PREDIÇÕES DE NOVOS CASOS
dados_novos_casos <- read.csv("6 - Veiculos - Novos Dados.csv")
View(dados_novos_casos)

predict.rna <- predict(rna, dados_novos_casos)
dados_novos_casos$tipo <- NULL
resultado <- cbind(dados_novos_casos, predict.rna)
resultado
```

Diabetes

Técnica	Parâmetro	Acurácia	Matriz de Confusão
RNA – CV	size=11, decay=0.1	0.7647	Reference Prediction neg pos neg 89 25 pos 11 28
RF – Hold-out	mtry=2	0.7582	Reference Prediction neg pos neg 85 22 pos 15 31
RF – CV	mtry=5	0.7451	Reference Prediction neg pos neg 84 23 pos 16 30
RNA – Hold-out	size=3, decay=0.1	0.7451	Reference Prediction neg pos neg 82 21 pos 18 32
SVM – CV	C=0.25, Sigma= 0.1483148	0.732	Reference Prediction neg pos neg 86 27 pos 14 26
SVM – Hold-out	C=0.25, Sigma= 0.1483148	0.732	Reference Prediction neg pos neg 86 27 pos 14 26
KNN	k=9	0.7143	Reference Prediction neg pos neg 78 32 pos 12 32

Predição de novos casos:

	preg0nt	glucose	pressure	triceps	insulin	mass	pedigree	age	predict.rna
1	2	145	75	38	0	34	0.20	32	neg
2	3	90	62	33	168	27	2.29	21	pos
3	6	110	68	2	88	23	0.36	26	neg

Lista de comandos:

```
### Instalação dos pacotes necessários
#install.packages("e1071")
#install.packages("caret")
#install.packages("mlbench")
#install.packages("mice")
library(mlbench)
library("caret")

## Leitura dos dados
dados <- read.csv("10 - Diabetes - Dados.csv")

### Retira o atributo num
dados$num <- NULL
View(dados)

### Cria um arquivo com treino com 80% e teste com 20% das linhas de forma randomizada
set.seed(202475)
indices <- createDataPartition(dados$diabetes, p=0.80,list=FALSE)
treino <- dados[indices,]
teste <- dados[-indices,]

### indica o método cv e numero de folders 10
ctrl <- trainControl(method = "cv", number = 10)

### executa a RNA com esse ctrl
set.seed(202475)
rna <- train(diabetes~., data=treino, method="nnet",trace=FALSE, trControl=ctrl)
predict.rna <- predict(rna, teste)
confusionMatrix(predict.rna, as.factor(teste$diabetes))
```

```
#parametrização da RNA
### size, decay
grid <- expand.grid(size = seq(from = 1, to = 35, by = 10), decay = seq(from = 0.1, to = 0.6, by = 0.3))
set.seed(202475)
rna <- train(
  form = diabetes~. ,
  data = treino ,
  method = "nnet" ,
  tuneGrid = grid ,
  trControl = ctrl ,
  maxit = 2000,trace=FALSE)
```

```
# Exibir o modelo treinado
rna

### Faz as predições e mostra matriz de confusão
predict.rna <- predict(rna, teste)
confusionMatrix(predict.rna, as.factor(teste$diabetes))

### PREDIÇÕES DE NOVOS CASOS
dados_novos_casos <- read.csv("10 - Diabetes - Novos Dados.csv")
View(dados_novos_casos)

predict.rna <- predict(rna, dados_novos_casos)
dados_novos_casos$diabetes <- NULL
resultado <- cbind(dados_novos_casos, predict.rna)
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:
  - 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
  - A lista de comandos emitidos no RStudio para conseguir os resultados obtidos

Admissão

Técnica	Parâmetro	R2	Syx	Pearson	Rmse	MAE
RNA – CV	size=10, decay=0.1	0.8172428	0.061240715	0.90526694	0.060612589	0.045849687
RF – Hold-out	mtry=2	0.8114712	0.062200211	0.90167994	0.061562243	0.042709547
RF – CV	mtry=2	0.809526 13	0.062520251	0.900782 55	0.061879	0.042564919
SVM – Hold-out	C=0.5, Sigma= 0.174971	0.807239 05	0.062894481	0.902271 64	0.062249393	0.043032732
SVM – CV	C=1, Sigma= 0.1749711	0.806472 06	0.063019484	.9012751 9	0.062373113	0.042353704
RNA – Hold-out	size=5, decay=0.1	0.801807 08	0.063774502	0.898292 29	0.063120388	0.049289792
KNN	K=9	0.713566 58	0.076668127	0.846452 02	0.075881766	0.057946712

Predição de novos casos:

```
  GRE.Score TOEFL.Score University.Rating SOP LOR CGPA Research predict.rna
1       300         105                 5 4.5 3.0  7.9        1        0.69
2       331          99                 3 4.0 2.0  8.4        0        0.61
3       305         107                 4 3.0 3.5  9.0        1        0.79
```

Gráfico de Resíduos:

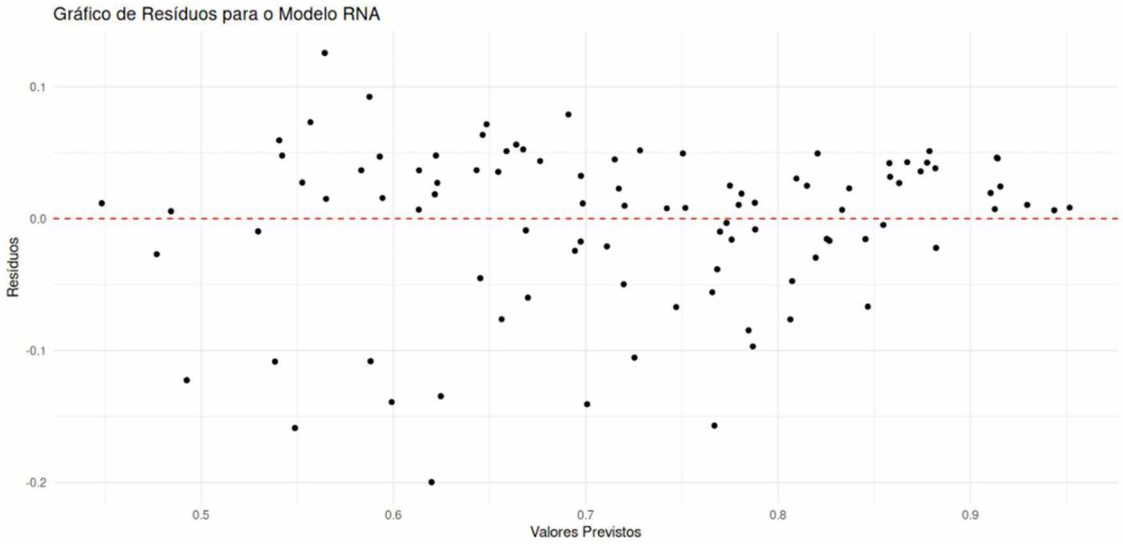

Lista de comandos:

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

## Leitura dos dados
dados <- read.csv("9 - Admissao - Dados.csv")

### Retira o atributo num
dados$num <- NULL
View(dados)

### Cria arquivos de treino e teste
set.seed(202475)
ind <- createDataPartition(dados$ChanceOfAdmit, p=0.80, list = FALSE)
treino <- dados[ind,]
teste <- dados[-ind,]

### CV e parametrizacao da RNA
control <- trainControl(method = "cv", number = 10)
tuneGrid <- expand.grid(size = seq(from = 1, to = 10, by = 1), decay = seq(from = 0.1, to = 0.9, by = 0.3))

set.seed(202475)
rna <- train(ChanceOfAdmit~., data=treino, method="nnet", trainControl=control, tuneGrid=tuneGrid, linout=T,
             MaxNWts=10000, maxit=2000, trace=F)
rna
```

```
### Predições e métricas
predicoes.rna <- predict(rna, teste)
rmse_valor <- rmse(teste$ChanceOfAdmit, predicoes.rna)
r2_valor <- r2(predicoes.rna, teste$ChanceOfAdmit)

# Cálculo do Erro Padrão da Estimativa (Syx)
syx <- function(observado, predito) {
  sqrt(sum((observado - predito)^2) / (length(observado) - 2))
}

syx_valor <- syx(teste$ChanceOfAdmit, predicoes.rna)
```

```r
# Cálculo do Coeficiente de Correlação de Pearson
pearson_valor <- cor(teste$ChanceOfAdmit, predicoes.rna)

# Cálculo do MAE
mae <- function(observado, predito) {
  mean(abs(predito - observado))
}

mae_valor <- mae(teste$ChanceOfAdmit, predicoes.rna)

# Resultados
resultados <- list(
  R2 = format(r2_valor, digits = 8),
  Syx = format(syx_valor, digits = 8),
  Pearson = format(pearson_valor, digits = 8),
  RMSE = format(rmse_valor, digits = 8),
  MAE = format(mae_valor, digits = 8)
)

print(resultados)
```

```r
# Calculo dos resíduos
residuos <- teste$ChanceOfAdmit - predicoes.rna

# Cria um data frame para o ggplot
df_residuos <- data.frame(predicoes = predicoes.rna, residuos = residuos)

# Crie o gráfico de resíduos
ggplot(df_residuos, aes(x = predicoes, y = residuos)) +
  geom_point() +
  geom_hline(yintercept = 0, linetype = "dashed", color = "red") +
  labs(title = "Gráfico de Resíduos para o Modelo RNA",
       x = "Valores Previstos",
       y = "Resíduos") +
  theme_minimal()

### PREDIÇÕES DE NOVOS CASOS
dados_novos_casos <- read.csv("9 - Admissao - Novos Dados.csv")
View(dados_novos_casos)

predict.rna <- predict(rna, dados_novos_casos)
dados_novos_casos$ChanceOfAdmit <- NULL
resultado <- cbind(dados_novos_casos, predict.rna)
resultado
```

Biomassa

Técnica	Parâmetro	R2	Syx	Pearson	Rmse	MAE
RF – CV	mtry=2	0.91359863	396.03396	0.9671900 6	389.37745	102.82337
RF – Hold-out	mtry=2	0.89921349	427.73355	0.9624069 1	420.54423	106.57287
RNA – CV	size=8, decay=0.7	0.797106	606.88543	0.9059203 5	596.68495	154.11875
KNN	K=9	0.78619982	622.98291	0.9101603 8	612.51186	180.985
SVM – CV	C=0.25, Sigma= 4.342076	0.43398421	1013.6462	0.7218538 5	996.60887	250.34411
SVM – Hold-out	C=0.25, Sigma= 4.342076	0.43398421	1013.6462	0.7218538 5	996.60887	250.34411

RNA – Hold-out	size=5, decay=0.1	0.014193276	1337.7285	0.8499397 5	1315.2441	448.10302

Predição de novos casos:

```
  dap   h   Me predict.rf
1 7.9 4.0 0.80         16
2 6.5 5.5 0.83         14
3 6.8 5.7 1.06         15
```

Gráfico de Resíduos:

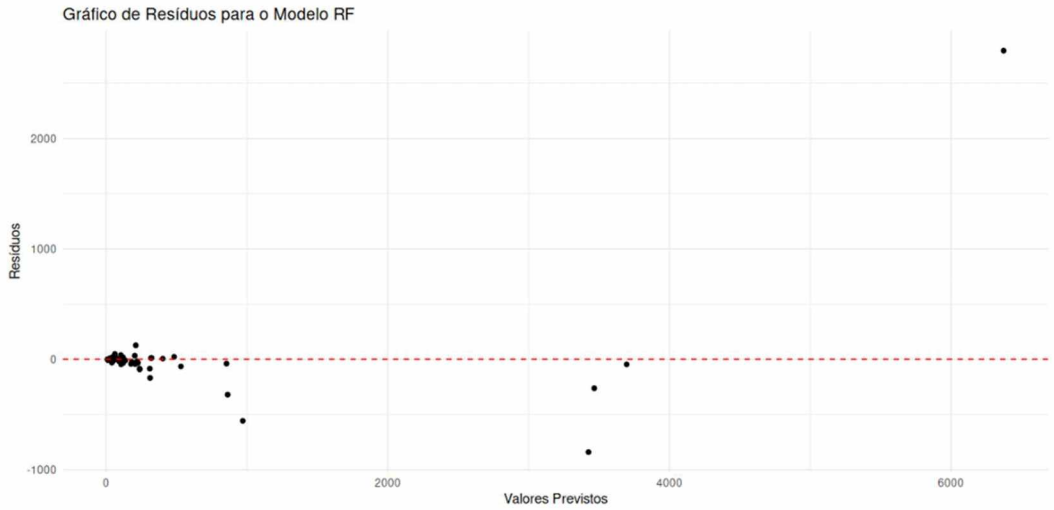

```r
### Calcular as métricas
rmse_valor <- rmse(teste$biomassa, predicoes.rf)
r2 <- function(predito, observado) {
  return(1 - (sum((predito-observado)^2) / sum((observado-mean(observado))^2)))
}
r2_valor <- r2(predicoes.rf ,teste$biomassa)

# Cálculo do Erro Padrão da Estimativa (Syx)
syx <- function(observado, predito) {
  sqrt(sum((observado - predito)^2) / (length(observado) - 2))
}

syx_valor <- syx(teste$biomassa, predicoes.rf)

# Cálculo do Coeficiente de Correlação de Pearson
pearson_valor <- cor(teste$biomassa, predicoes.rf)

# Cálculo do MAE
mae <- function(observado, predito) {
  mean(abs(predito - observado))
}

mae_valor <- mae(teste$biomassa, predicoes.rf)

# Resultados
resultados <- list(
  R2 = format(r2_valor, digits = 8),
  Syx = format(syx_valor, digits = 8),
  Pearson = format(pearson_valor, digits = 8),
  RMSE = format(rmse_valor, digits = 8),
  MAE = format(mae_valor, digits = 8)
)

resultados
```


```r
### Calcular as métricas
rmse_valor <- rmse(teste$biomassa, predicoes.rf)
r2 <- function(predito, observado) {
  return(1 - (sum((predito-observado)^2) / sum((observado-mean(observado))^2)))
}
r2_valor <- r2(predicoes.rf ,teste$biomassa)

# Cálculo do Erro Padrão da Estimativa (Syx)
syx <- function(observado, predito) {
  sqrt(sum((observado - predito)^2) / (length(observado) - 2))
}

syx_valor <- syx(teste$biomassa, predicoes.rf)

# Cálculo do Coeficiente de Correlação de Pearson
pearson_valor <- cor(teste$biomassa, predicoes.rf)

# Cálculo do MAE
mae <- function(observado, predito) {
  mean(abs(predito - observado))
}

mae_valor <- mae(teste$biomassa, predicoes.rf)
```

```r
# Resultados
resultados <- list(
  R2 = format(r2_valor, digits = 8),
  Syx = format(syx_valor, digits = 8),
  Pearson = format(pearson_valor, digits = 8),
  RMSE = format(rmse_valor, digits = 8),
  MAE = format(mae_valor, digits = 8)
)
```

```
resultados

# Calculo dos resíduos
residuos <- teste$biomassa - predicoes.rf

# Cria um data frame para o ggplot
df_residuos <- data.frame(predicoes = predicoes.rf, residuos = residuos)

# Crie o gráfico de resíduos
ggplot(df_residuos, aes(x = predicoes, y = residuos)) +
  geom_point() +
  geom_hline(yintercept = 0, linetype = "dashed", color = "red") +
  labs(title = "Gráfico de Resíduos para o Modelo RF",
       x = "Valores Previstos",
       y = "Resíduos") +
  theme_minimal()

### PREDIÇÕES DE NOVOS CASOS
dados_novos_casos <- read.csv("5 - Biomassa - Novos Dados.csv")
View(dados_novos_casos)

predict.rf <- predict(rf, dados_novos_casos)
dados_novos_casos$biomassa <- NULL
resultado <- cbind(dados_novos_casos, predict.rf)
resultado
```

AGRUPAMENTO

Veículo

Lista de Clusters gerados:

10 primeiras linhas do arquivo com o cluster correspondente.
Usa 10 clusters no experimento.

```
Cluster modes:
   Comp Circ DCirc RadRa PrAxisRa MaxLRa ScatRa Elong PrAxisRect MaxLRect ScVarMaxis ScVarmaxis RaGyr SkewMaxis Skewmaxis KurtMaxis KurtMaxis HollRa tipo
1    86   37    66   126       56      7    128    52         18       127        159        246   132       85         1         6       201    183  van
2    89   45    85   150       64     10    155    45         19       144        169        554   187       72         5         9       188    196  van
3    93   38    74   176       59      7    169    39         20       131        184        259   137       67         1         3       192    202 opel
4   101   55   101   193       62     10    212    31         24       159        219        682   214       74         5        11       187    197 opel
5    89   36    66   136       58      7    144    46         19       128        164        334   127       66         0        14       181    185 saab
6   104   54   103   209       57     11    213    31         24       162        223        706   218       72         0        19       188    198 opel
7    89   40    83   197       63      9    177    37         21       139        197        290   151       71         4         1       189    198 opel
8    82   43    70   141       64      7    151    44         19       143        175        341   172       75         4         0       183    187  bus
9    85   43    70   120       54      7    150    45         19       145        170        527   173       85         6        12       188    184  bus
10   89   46    85   162       64     11    157    43         20       148        178        363   186       68         1        11       189    199 saab
```

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

```
### Instalação dos pacotes necessários
install.packages("klaR")
library(klaR)

## Leitura dos dados
dados <- read.csv("6 - Veiculos - Dados.csv")

### Retira o atributo a
dados$a <- NULL
View(dados)

### Resultados
set.seed(202475)
cluster.results <- kmodes(dados, 10, iter.max = 10, weighted = FALSE )
cluster.results
```

REGRAS DE ASSOCIAÇÃO

Musculação

Regras geradas com uma configuração de Suporte e Confiança.

```
summary of quality measures:
    support         confidence        coverage            lift           count
 Min.   :0.03846   Min.   :0.7000   Min.   :0.03846   Min.   :0.8667   Min.   : 1.000
 1st Qu.:0.07692   1st Qu.:0.8571   1st Qu.:0.07692   1st Qu.:1.5294   1st Qu.: 2.000
 Median :0.07692   Median :1.0000   Median :0.07692   Median :1.7143   Median : 2.000
 Mean   :0.14665   Mean   :0.9328   Mean   :0.16799   Mean   :1.7468   Mean   : 3.813
 3rd Qu.:0.23077   3rd Qu.:1.0000   3rd Qu.:0.26923   3rd Qu.:2.0000   3rd Qu.: 6.000
 Max.   :0.46154   Max.   :1.0000   Max.   :0.65385   Max.   :3.2500   Max.   :12.000
```

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

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

## Leitura dos dados
dados <- read.transactions(file="2 - Musculacao - Dados.csv",format="basket",sep=";")
inspect(dados[1:4])

### Podemos ver a frequência dos 10 primeiros itens:
itemFrequencyPlot(dados, topN=10, type='absolute')


### Suporte=0,001 e Confiança=0,7
set.seed(202475)
rules <- apriori(dados, parameter = list(supp = 0.001, conf = 0.7, minlen=2))
summary(rules)
```

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

CLASSIFICAÇÃO DE IMAGENS

Usando a base de dados CIFAR10 e o algoritmo CNN para solução. Iniciou-se pelo download dos dados e separação em treino e teste:

```
Downloading data from https://www.cs.toronto.edu/~kriz/cifar-10-python.tar.gz
170498071/170498071 ━━━━━━━━━━━━━━━━━━━━ 5s 0us/step

x_train.shape:  (50000, 32, 32, 3)
y_train.shape:  (50000,)
x_test.shape:  (10000, 32, 32, 3)
y_test.shape:  (10000,)
```

Configurou-se o modelo CNN com as camadas:

Model: "functional"

Layer (type)	Output Shape	Param #
input_layer (InputLayer)	(None, 32, 32, 3)	0
conv2d (Conv2D)	(None, 15, 15, 32)	896
conv2d_1 (Conv2D)	(None, 7, 7, 64)	18,496
conv2d_2 (Conv2D)	(None, 3, 3, 128)	73,856
flatten (Flatten)	(None, 1152)	0
dropout (Dropout)	(None, 1152)	0
dense (Dense)	(None, 1024)	1,180,672
dropout_1 (Dropout)	(None, 1024)	0
dense_1 (Dense)	(None, 10)	10,250

Total params: 1,284,170 (4.90 MB)
Trainable params: 1,284,170 (4.90 MB)
Non-trainable params: 0 (0.00 B)

Treinamento com 15 épocas:

```
Epoch 1/15
1563/1563 ━━━━━━━━━━━━━━━━━━━━ 114s 71ms/step - accuracy: 0.3589 - loss: 1.7515 - val_accuracy: 0.5271 - val_loss: 1.3005
Epoch 2/15
1563/1563 ━━━━━━━━━━━━━━━━━━━━ 152s 77ms/step - accuracy: 0.5229 - loss: 1.3222 - val_accuracy: 0.5848 - val_loss: 1.1605
Epoch 3/15
1563/1563 ━━━━━━━━━━━━━━━━━━━━ 111s 71ms/step - accuracy: 0.5718 - loss: 1.1901 - val_accuracy: 0.6094 - val_loss: 1.0893
Epoch 4/15
1563/1563 ━━━━━━━━━━━━━━━━━━━━ 150s 76ms/step - accuracy: 0.6092 - loss: 1.0783 - val_accuracy: 0.6436 - val_loss: 0.9967
Epoch 5/15
1563/1563 ━━━━━━━━━━━━━━━━━━━━ 140s 89ms/step - accuracy: 0.6396 - loss: 1.0163 - val_accuracy: 0.6669 - val_loss: 0.9495
Epoch 6/15
1563/1563 ━━━━━━━━━━━━━━━━━━━━ 119s 75ms/step - accuracy: 0.6605 - loss: 0.9496 - val_accuracy: 0.6678 - val_loss: 0.9429
Epoch 7/15
1563/1563 ━━━━━━━━━━━━━━━━━━━━ 141s 74ms/step - accuracy: 0.6809 - loss: 0.8918 - val_accuracy: 0.6862 - val_loss: 0.8958
Epoch 8/15
1563/1563 ━━━━━━━━━━━━━━━━━━━━ 107s 68ms/step - accuracy: 0.7024 - loss: 0.8338 - val_accuracy: 0.6829 - val_loss: 0.8989
Epoch 9/15
1563/1563 ━━━━━━━━━━━━━━━━━━━━ 154s 76ms/step - accuracy: 0.7143 - loss: 0.8003 - val_accuracy: 0.6988 - val_loss: 0.8611
Epoch 10/15
1563/1563 ━━━━━━━━━━━━━━━━━━━━ 136s 73ms/step - accuracy: 0.7257 - loss: 0.7660 - val_accuracy: 0.6983 - val_loss: 0.8543
Epoch 11/15
1563/1563 ━━━━━━━━━━━━━━━━━━━━ 142s 73ms/step - accuracy: 0.7389 - loss: 0.7336 - val_accuracy: 0.7003 - val_loss: 0.8600
Epoch 12/15
1563/1563 ━━━━━━━━━━━━━━━━━━━━ 145s 75ms/step - accuracy: 0.7494 - loss: 0.7010 - val_accuracy: 0.7104 - val_loss: 0.8246
Epoch 13/15
1563/1563 ━━━━━━━━━━━━━━━━━━━━ 117s 75ms/step - accuracy: 0.7595 - loss: 0.6769 - val_accuracy: 0.7097 - val_loss: 0.8225
Epoch 14/15
1563/1563 ━━━━━━━━━━━━━━━━━━━━ 148s 79ms/step - accuracy: 0.7648 - loss: 0.6528 - val_accuracy: 0.7117 - val_loss: 0.8214
Epoch 15/15
1563/1563 ━━━━━━━━━━━━━━━━━━━━ 139s 77ms/step - accuracy: 0.7722 - loss: 0.6402 - val_accuracy: 0.7101 - val_loss: 0.8366
```

Perda e acurácia durante treinamento:

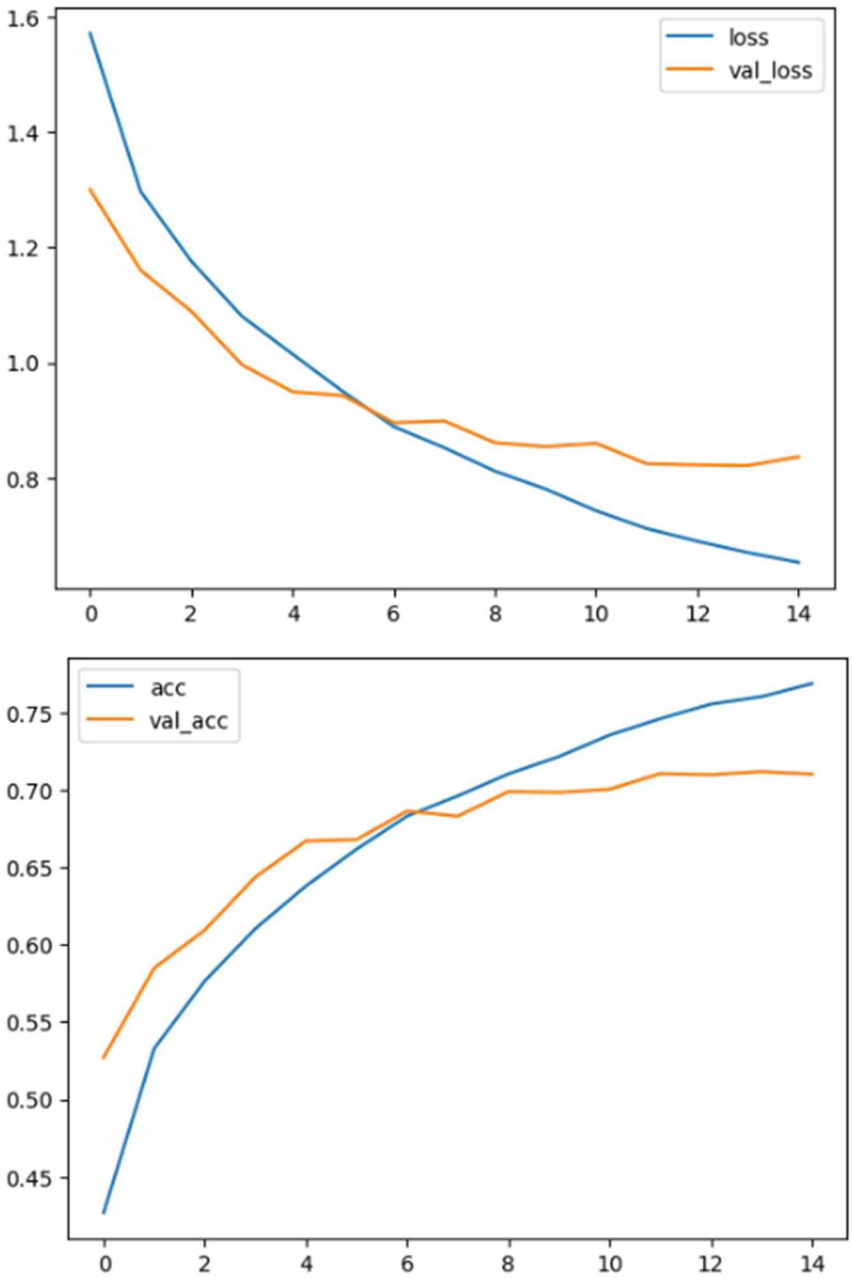

Matrix de confusão, pós treinamento:

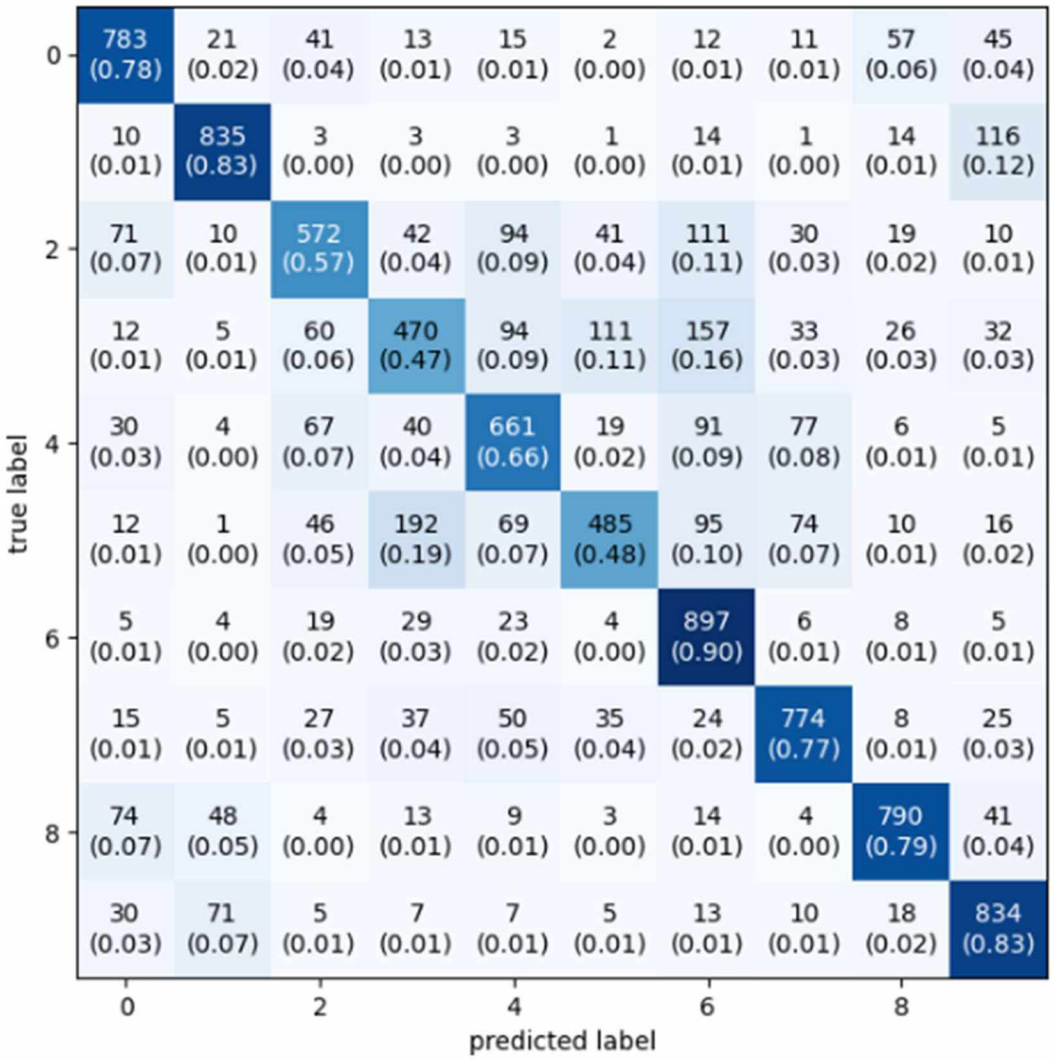

Exemplo de errada:

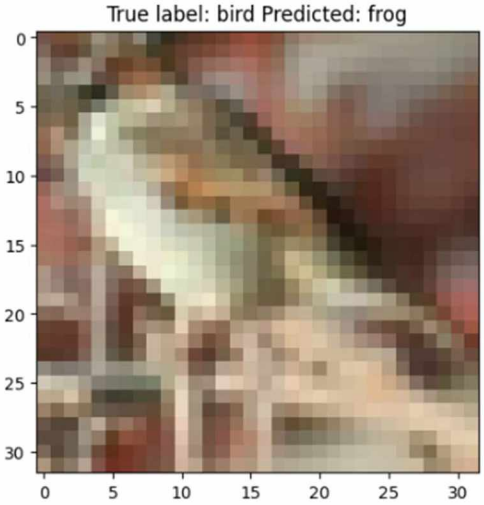

Detector de spam

Usando base de mensagens SMS, implementamos um algoritmo RNN para detecção de SPAM. Iniciamos com o download da base, separação em treino e teste e tokenização com limite por frequência:

```
--2024-08-18 02:27:17--  https://filebin.net/o7trbqexn1eg7706/spam.csv
Resolving filebin.net (filebin.net)... 88.99.137.18, 2a01:4f8:10a:2156::2
Connecting to filebin.net (filebin.net)|88.99.137.18|:443... connected.
HTTP request sent, awaiting response... 302 Found
Location: https://s3.filebin.net/filebin/4c8b12ad0793c5b0859130617115ec2fab8b9291
--2024-08-18 02:27:18--  https://s3.filebin.net/filebin/4c8b12ad0793c5b085913061
Resolving s3.filebin.net (s3.filebin.net)... 88.99.137.18, 2a01:4f8:10a:2156::2
Connecting to s3.filebin.net (s3.filebin.net)|88.99.137.18|:443... connected.
HTTP request sent, awaiting response... 200 OK
Length: 503663 (492K) [text/csv]
Saving to: 'spam.csv.1'

spam.csv.1          100%[===================>] 491.86K   867KB/s    in 0.6s

2024-08-18 02:27:19 (867 KB/s) - 'spam.csv.1' saved [503663/503663]

7127 tokens


data_train.shape:  (3733, 189)
data_test.shape:  (1839, 189)
```

Criamos o modelo RNN com algoritmo LSTM:

Model: "functional"

Layer (type)	Output Shape	Param #
input_layer (InputLayer)	(None, 189)	0
embedding (Embedding)	(None, 189, 20)	142,560
lstm (LSTM)	(None, 5)	520
dense (Dense)	(None, 1)	6

Total params: 143,086 (558.93 KB)
Trainable params: 143,086 (558.93 KB)
Non-trainable params: 0 (0.00 B)

Treinamos com 5 épocas:

```
Epoch 1/5
117/117 ━━━━━━━━━━━━━━━━━━━━ 21s 146ms/step - accuracy: 0.8170 - loss: 0.5888 - val_accuracy: 0.8923 - val_loss: 0.2952
Epoch 2/5
117/117 ━━━━━━━━━━━━━━━━━━━━ 20s 170ms/step - accuracy: 0.9404 - loss: 0.2392 - val_accuracy: 0.9668 - val_loss: 0.1656
Epoch 3/5
117/117 ━━━━━━━━━━━━━━━━━━━━ 20s 167ms/step - accuracy: 0.9874 - loss: 0.1446 - val_accuracy: 0.9793 - val_loss: 0.1185
Epoch 4/5
117/117 ━━━━━━━━━━━━━━━━━━━━ 17s 139ms/step - accuracy: 0.9929 - loss: 0.0995 - val_accuracy: 0.9869 - val_loss: 0.0933
Epoch 5/5
117/117 ━━━━━━━━━━━━━━━━━━━━ 18s 154ms/step - accuracy: 0.9958 - loss: 0.0706 - val_accuracy: 0.9869 - val_loss: 0.0743
```

Gráfico de perda e acurácia durante treinamento:

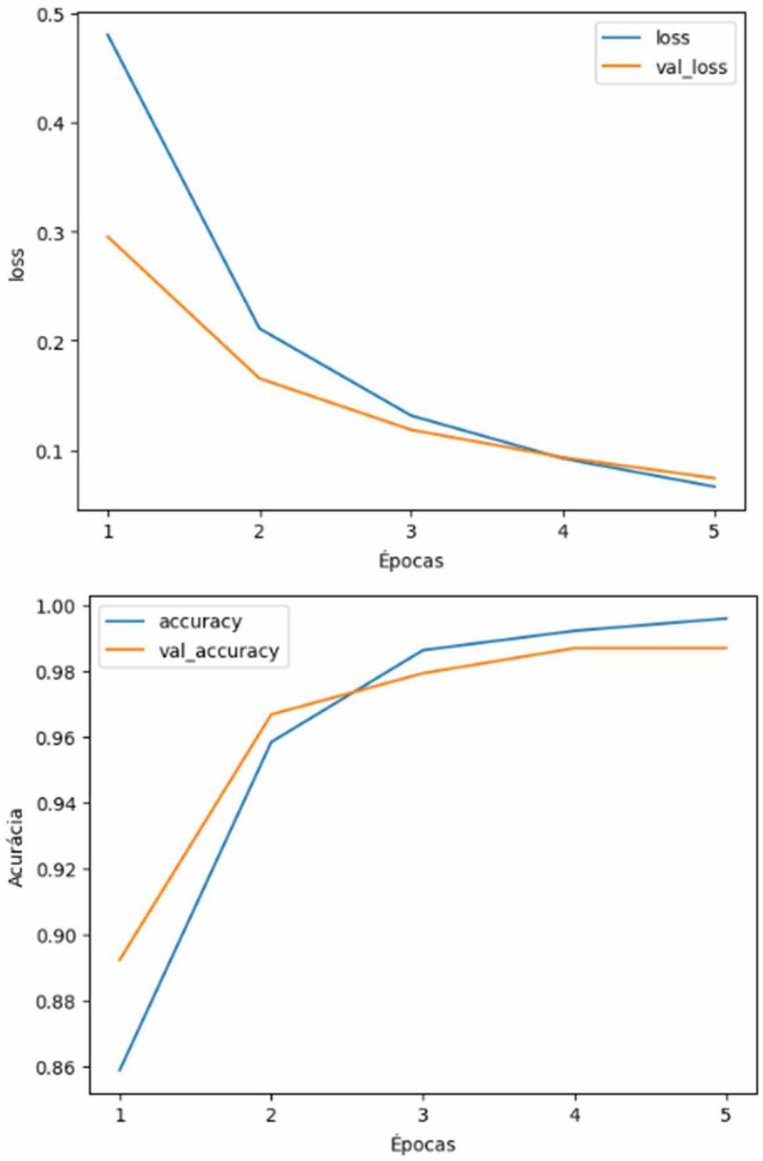

Exemplo de detecção de SPAM com o modelo treinado, para a frase “Is your car dirty? Discover our new product. Free for all. Click the link.”

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 51ms/step
[[0.65158933]]
SPAM
```

Gerador de dígitos fake

Com dados do MNIST, implementamos a arquitetura GAN para gerar dígitos. Usamos as libs imageio e tensor flow. Iniciamos com download da base:

```
Downloading data from https://storage.googleapis.com/tensorflow/tf-keras-datasets/mnist.npz
11490434/11490434 ━━━━━━━━━━━━━━━━━━━━ 0s 0us/step
```

Montamos o modelo de geração e fizemos um teste com ele sem estar treinado:

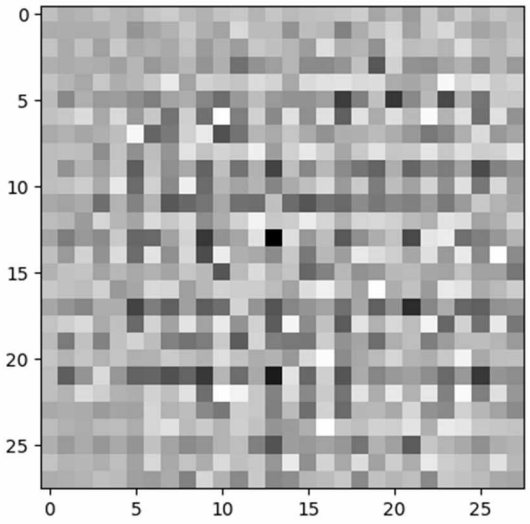

Da mesma forma com o discriminador:

```
tf.Tensor([[0.00541993]], shape=(1, 1), dtype=float32)
```

Criamos funções para calcular perda do discriminador e gerador, uma função de treinamento que combina as duas técnicas, com otimizador adam e uma estrutura para salvar o treinamento (checkpoint) caso o treinamento seja interrompido. Realizamos o treinamento de 100 épocas, salvando cada imagem gerada:

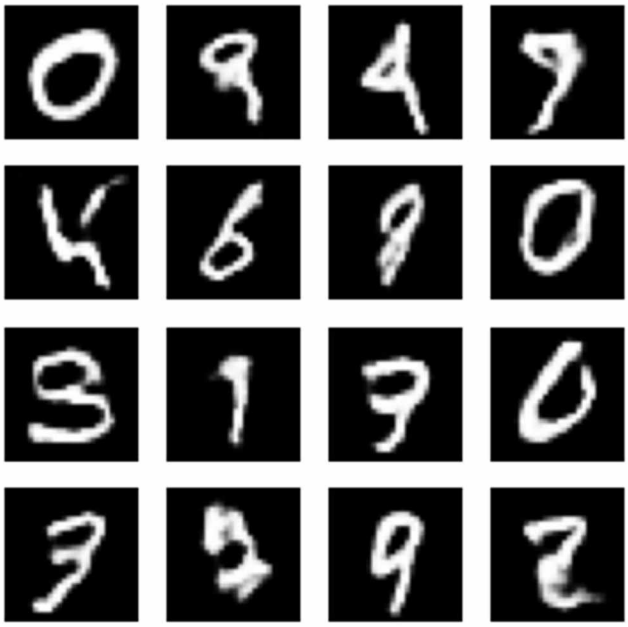

```
Time for epoch 60 is 12.108076572418213 sec
```

Após o treinamento, combinamos as imagens geradas formando o GIF abaixo:

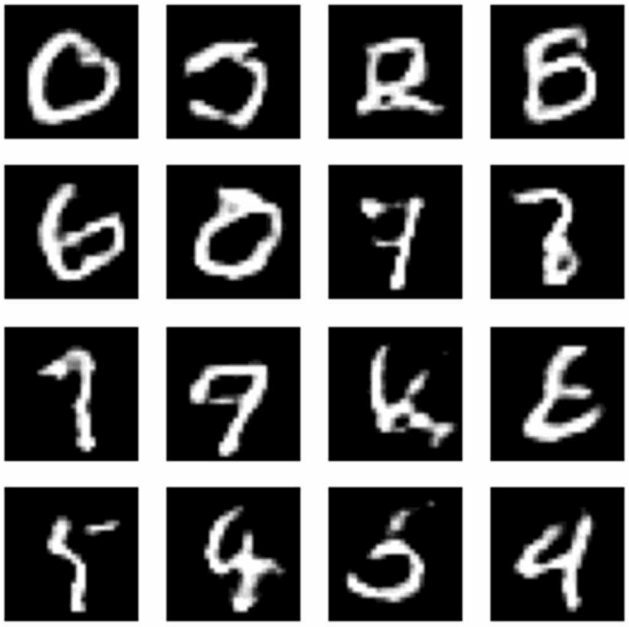

Tradutor de texto

Para construir um tradutor de textos, usando a técnica de Transformer, usamos a biblioteca TensorFlow e o conjunto de dados derivados de transcrições de palestras do TED. Iniciamos com o download:

```
WARNING:absl:Variant folder /root/tensorflow_datasets/ted_hrlr_translate/pt_to_en/1.0.0 has no dataset_info.json
Downloading and preparing dataset Unknown size (download: Unknown size, generated: Unknown size, total: Unknown size) to /root/tensorflow_datasets/ted_hrlr_translate/pt_to_en/1.0.0...
Dl Completed...: 100% 1/1 [00:04<00:00,  2.12s/ url]
Dl Size...: 100% 124/124 [00:04<00:00, 60.53 MiB/s]
Extraction completed...: 100% 112/112 [00:04<00:00,  4.81s/ file]
Dataset ted_hrlr_translate downloaded and prepared to /root/tensorflow_datasets/ted_hrlr_translate/pt_to_en/1.0.0. Subsequent calls will reuse this data.
```

Depois de carregar os dados, exibimos uma amostra para validação:

```
e quando melhoramos a procura , tiramos a única vantagem da impressão , que é a serendipidade .
mas e se estes fatores fossem ativos ?
mas eles não tinham a curiosidade de me testar .

and when you improve searchability , you actually take away the one advantage of print , which is serendipity .
but what if it were active ?
but they did n't test for curiosity .
```

Visualizamos como a codificação posicional varia com a posição e a dimensão do *embedding*.

```
(1, 2048, 512)
```

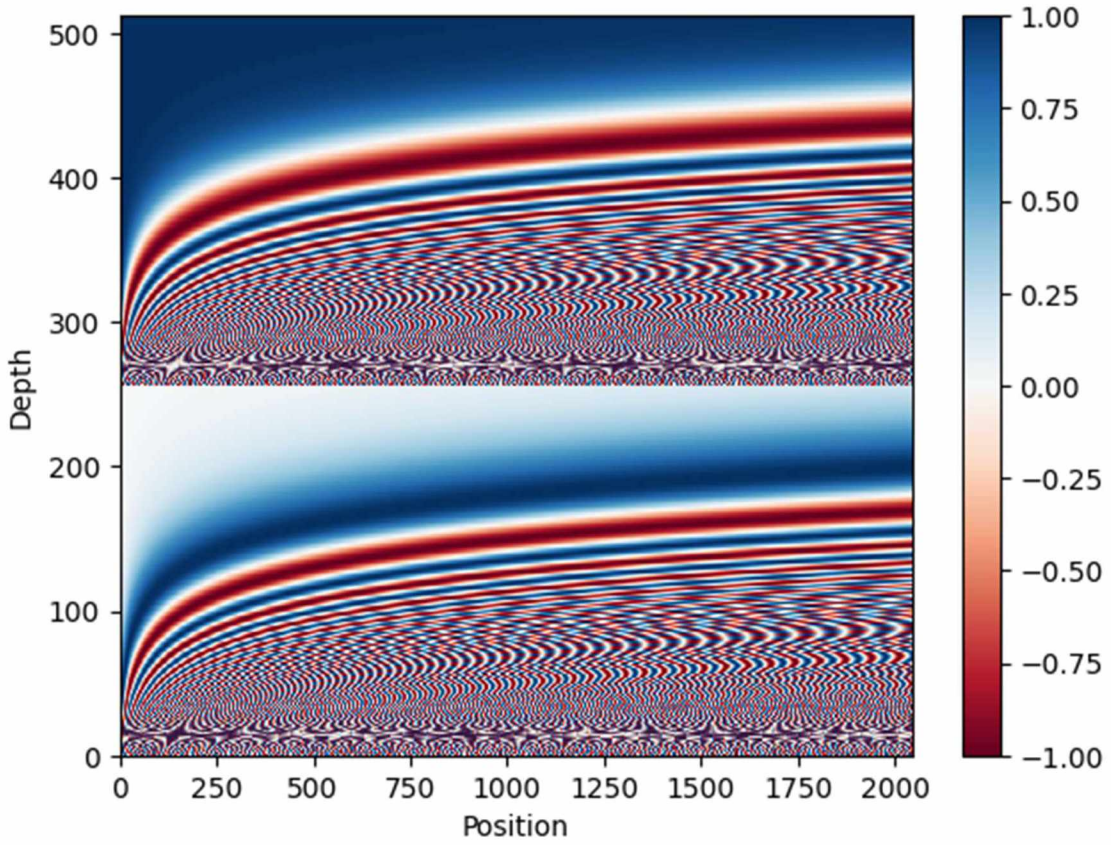

Visualizamos o modelo depois de construído:

```
Model: "transformer_1"
```

Layer (type)	Output Shape	Param #
encoder_1 (Encoder)	?	0 (unbuilt)
decoder_1 (Decoder)	?	0 (unbuilt)
dense_129 (Dense)	?	0 (unbuilt)

```
Total params: 0 (0.00 B)
Trainable params: 0 (0.00 B)
Non-trainable params: 0 (0.00 B)
```

Treinamento feito em 20 épocas salvando cada etapa (checkpoints):

```
Epoch 19 Batch 0 Loss 1.3288 Accuracy 0.6962
Epoch 19 Batch 50 Loss 1.4567 Accuracy 0.6781
Epoch 19 Batch 100 Loss 1.4462 Accuracy 0.6799
Epoch 19 Batch 150 Loss 1.4516 Accuracy 0.6792
Epoch 19 Batch 200 Loss 1.4543 Accuracy 0.6783
Epoch 19 Batch 250 Loss 1.4580 Accuracy 0.6779
Epoch 19 Batch 300 Loss 1.4573 Accuracy 0.6779
Epoch 19 Batch 350 Loss 1.4582 Accuracy 0.6780
Epoch 19 Batch 400 Loss 1.4614 Accuracy 0.6776
Epoch 19 Batch 450 Loss 1.4669 Accuracy 0.6767
Epoch 19 Batch 500 Loss 1.4692 Accuracy 0.6765
Epoch 19 Batch 550 Loss 1.4708 Accuracy 0.6760
Epoch 19 Batch 600 Loss 1.4744 Accuracy 0.6755
Epoch 19 Batch 650 Loss 1.4775 Accuracy 0.6748
Epoch 19 Batch 700 Loss 1.4796 Accuracy 0.6747
Epoch 19 Batch 750 Loss 1.4817 Accuracy 0.6744
Epoch 19 Batch 800 Loss 1.4834 Accuracy 0.6743
Epoch 19 Loss 1.4836 Accuracy 0.6742
Time taken for 1 epoch: 98.27 secs

Epoch 20 Batch 0 Loss 1.2931 Accuracy 0.7111
Epoch 20 Batch 50 Loss 1.3878 Accuracy 0.6894
Epoch 20 Batch 100 Loss 1.4033 Accuracy 0.6874
Epoch 20 Batch 150 Loss 1.4096 Accuracy 0.6861
Epoch 20 Batch 200 Loss 1.4101 Accuracy 0.6866
Epoch 20 Batch 250 Loss 1.4153 Accuracy 0.6855
Epoch 20 Batch 300 Loss 1.4151 Accuracy 0.6856
Epoch 20 Batch 350 Loss 1.4191 Accuracy 0.6846
Epoch 20 Batch 400 Loss 1.4209 Accuracy 0.6842
Epoch 20 Batch 450 Loss 1.4253 Accuracy 0.6834
Epoch 20 Batch 500 Loss 1.4289 Accuracy 0.6828
Epoch 20 Batch 550 Loss 1.4319 Accuracy 0.6823
Epoch 20 Batch 600 Loss 1.4346 Accuracy 0.6816
Epoch 20 Batch 650 Loss 1.4362 Accuracy 0.6813
Epoch 20 Batch 700 Loss 1.4400 Accuracy 0.6808
Epoch 20 Batch 750 Loss 1.4431 Accuracy 0.6803
Epoch 20 Batch 800 Loss 1.4468 Accuracy 0.6798
Saving checkpoint for epoch 20 at ./checkpoints/train/ckpt-10
Epoch 20 Loss 1.4476 Accuracy 0.6798
Time taken for 1 epoch: 97.16 secs
```

Teste da predição, com o modelo treinado, usando a frase: “Eu li sobre triceratops na enciclopédia.”

```
Prediction     : b'i read about thornal thornass in encyclood .'
```

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

Estudo de Caso

Aplicação de Big Data em E-commerce com Ferramentas NoSQL e NewSQL

Introdução

No cenário competitivo do comércio eletrônico, empresas líderes como **Amazon**, **Netflix** e **Uber** lidam diariamente com volumes massivos de dados provenientes de transações, interações de usuários, avaliações de produtos e atividades em redes sociais. Gerenciar e extrair valor desses dados é essencial para melhorar a experiência do cliente, otimizar operações e impulsionar as vendas. Este estudo de caso explora como essas empresas utilizam ferramentas de Big Data, especificamente bancos de dados NoSQL e NewSQL, para atender às suas demandas de processamento e análise de dados.

Caracterização dos Dados e dos Vs

Essas empresas enfrentam desafios relacionados aos cinco Vs do Big Data:

- **Volume**:
  - **Amazon**: Processa petabytes de dados diariamente, incluindo histórico de compras, navegação no site e interações em tempo real [1].
  - **Netflix**: Gerencia enormes volumes de dados de streaming e preferências de milhões de usuários globalmente [2].
  - **Uber**: Lida com dados geoespaciais e transações em tempo real de milhões de corridas diárias [3].

- **Velocidade**:
  - **Amazon**: Necessita de atualizações em milissegundos para inventário e processamento de pedidos [4].

- **Uber**: Calcula rotas e tarifas em tempo real, exigindo processamento instantâneo de dados [5].
- **Netflix**: Oferece recomendações imediatas baseadas no comportamento atual do usuário [6].

- **Variedade**:
  - **Amazon**: Dados estruturados (transações), semi-estruturados (logs de cliques) e não estruturados (comentários, avaliações) [7].
  - **Netflix**: Dados de streaming, logs de reprodução, interações do usuário e métricas de qualidade de serviço [8].
  - **Uber**: Dados geoespaciais, transações financeiras, feedback de usuários e dados de tráfego [9].

- **Veracidade**:
  - **Amazon**: Investe em sistemas para garantir a autenticidade de avaliações e evitar fraudes [10].
  - **Uber**: Necessita de dados precisos para segurança e confiabilidade do serviço [11].
  - **Netflix**: Garante a qualidade dos dados para oferecer recomendações precisas [12].

- **Valor**:
  - **Amazon**: Utiliza análise de dados para personalizar ofertas e melhorar a satisfação do cliente [13].
  - **Uber**: Otimiza rotas e tempos de espera, melhorando a eficiência operacional [14].
  - **Netflix**: A análise de dados direciona a produção de conteúdo original e retenção de usuários [15].

Ferramentas Utilizadas

Para lidar com esses desafios, as empresas implementaram uma combinação de bancos de dados NoSQL e NewSQL.

Bancos de Dados NoSQL

Amazon DynamoDB (Amazon)

- **Uso**: A Amazon utiliza o DynamoDB para gerenciar dados de produtos, carrinhos de compras e sessões de usuários [16].

- **Benefícios**: Oferece latência de milissegundos em qualquer escala, permitindo que a Amazon mantenha alta performance durante picos de acesso, como na Black Friday.
- **Modelagem**: Adota um modelo de chave-valor e documento, proporcionando flexibilidade na estrutura dos dados.

Apache Cassandra (Netflix)

- **Uso**: A Netflix emprega o Cassandra para armazenar dados de streaming, preferências do usuário e histórico de visualização [17].
- **Benefícios**: Fornece alta disponibilidade e escalabilidade horizontal, essencial para o serviço global da Netflix.
- **Modelagem**: Utiliza um modelo de colunas largas, ideal para grandes volumes de dados e acessos rápidos.

Bancos de Dados NewSQL

Google Spanner (Google)

- **Uso**: Embora não seja uma empresa de e-commerce tradicional, o Google utiliza o Spanner para serviços que requerem consistência global, como transações financeiras no Google Ads [18].
- **Benefícios**: Combina a escalabilidade de sistemas NoSQL com transações ACID, garantindo consistência em escala global.
- **Modelagem**: Mantém um esquema relacional tradicional, facilitando consultas complexas com SQL padrão.

MemSQL (SingleStore) (Uber)

- **Uso**: A Uber utiliza o MemSQL para processar transações financeiras e dados de telemetria em tempo real [19].
- **Benefícios**: Oferece processamento rápido de transações e análises, suportando decisões em tempo real.
- **Modelagem**: Combina armazenamento em memória e disco, permitindo consultas rápidas sem sacrificar a persistência dos dados.
-

Modelagem Necessária

A escolha do modelo de dados adequado é fundamental para otimizar o desempenho e a eficiência dos sistemas.

Modelagem em NoSQL

- **Modelo de Documento (DynamoDB na Amazon)**:
  - **Estrutura**: Armazena dados em formatos flexíveis como JSON.
  - **Aplicação**: Permite à Amazon adicionar novos atributos aos produtos sem migrações complexas.
  - **Benefícios**: Escalabilidade e flexibilidade para acomodar diferentes tipos de produtos e categorias.

- **Modelo de Colunas Largas (Cassandra na Netflix)**:
  - **Estrutura**: Organiza dados em tabelas com linhas e colunas, mas com a capacidade de armazenar milhões de colunas.
  - **Aplicação**: Ideal para o histórico de visualização de usuários e logs de atividades.
  - **Benefícios**: Otimiza operações de gravação e leitura em grandes volumes de dados distribuídos.

Modelagem em NewSQL

- **Modelo Relacional Distribuído (Spanner no Google)**:
  - **Estrutura**: Mantém tabelas relacionais com suporte a transações ACID.
  - **Aplicação**: Gerencia dados que requerem consistência forte e transações distribuídas.
  - **Benefícios**: Combina a familiaridade do SQL com a escalabilidade necessária para operações globais.

- **Modelo Híbrido (MemSQL na Uber)**:
  - **Estrutura**: Une aspectos de bancos de dados relacionais e NoSQL, suportando SQL e armazenamento em memória.
  - **Aplicação**: Processa dados de corridas, pagamentos e localização em tempo real.
  - **Benefícios**: Permite análises rápidas e decisões imediatas sem comprometer a integridade dos dados.

Conclusão

A adoção de bancos de dados NoSQL e NewSQL permitiu que empresas como Amazon, Netflix e Uber superassem os desafios associados ao Big Data, proporcionando:

- **Melhor Desempenho**: Processamento eficiente de grandes volumes de dados em tempo real, melhorando a responsividade dos serviços e a satisfação do cliente.
- **Flexibilidade**: Capacidade de adaptar-se rapidamente a novas fontes de dados e requisitos de negócios sem reestruturações significativas do banco de dados.
- **Confiabilidade**: Garantia de integridade e consistência dos dados críticos, como transações financeiras e informações de inventário.

Os desafios enfrentados incluíram a complexidade na integração de diferentes sistemas de banco de dados e a necessidade de profissionais qualificados em tecnologias diversas. Essas empresas superaram esses obstáculos através de arquiteturas bem planejadas, investimentos em infraestrutura e foco no desenvolvimento de equipes especializadas.
Este estudo de caso destaca a importância de selecionar as ferramentas e modelos de dados apropriados para atender às necessidades específicas do negócio. Empresas líderes como **Amazon**, **Netflix** e **Uber** demonstram que o uso estratégico de tecnologias NoSQL e NewSQL é crucial para maximizar o valor extraído dos dados e manter a competitividade no mercado global de e-commerce.

Referências

1. Amazon Web Services. "DynamoDB: Under the Hood." *AWS re 2018*. Disponível em: https://aws.amazon.com/dynamodb/.
2. Netflix Tech Blog. "Netflix Recommendations: Beyond the 5 stars (Part 1)." *Medium*, 2012. Disponível em: https://netflixtechblog.com/.
3. Uber Engineering. "How Uber Engineering Uses Data to Improve the User Experience." *Uber Engineering Blog*, 2016. Disponível em: https://eng.uber.com/.
4. DeCandia, G. et al. "Dynamo: Amazon's Highly Available Key-value Store." *ACM SIGOPS Operating Systems Review*, vol. 41, no. 6, 2007.
5. Uber Engineering. "Geo-spatial Indexing with Uber H3." *Uber Engineering Blog*, 2018. Disponível em: https://eng.uber.com/h3/.
6. Amatriain, X. "Big & Personal: Data and Models Behind Netflix Recommendations." *Netflix Tech Blog*, 2013. Disponível em: https://netflixtechblog.com/.
7. Amazon Science. "How AI is Enhancing the Customer Experience at Amazon." *Amazon Science*, 2020. Disponível em: https://www.amazon.science/.
8. Netflix Tech Blog. "A Deep Dive into Netflix Personalization System." *Medium*, 2017. Disponível em: https://netflixtechblog.com/.
9. Uber Engineering. "Real-time Streaming Data Processing at Uber Using Apache Flink." *Uber Engineering Blog*, 2017. Disponível em: https://eng.uber.com/flink/.
10. Amazon. "Combating Fake Reviews and Ratings." *Amazon Official Site*, 2021. Disponível em: https://www.amazon.com.

11. Uber Newsroom. "Safety at Uber: Technology and Tools." *Uber Newsroom*, 2019. Disponível em: https://www.uber.com/newsroom/.
12. Gomez-Uribe, C. A., and Hunt, N. "The Netflix Recommender System: Algorithms, Business Value, and Innovation." *ACM Transactions on Management Information Systems*, vol. 6, no. 4, 2015.
13. Amazon Science. "Personalization and Recommendation." *Amazon Science*, 2019. Disponível em: https://www.amazon.science/.
14. Uber Engineering. "Optimizing Uber's Map Services." *Uber Engineering Blog*, 2018. Disponível em: https://eng.uber.com/maps/.

15. Netflix Investor Relations. "Q4 2019 Letter to Shareholders." *Netflix*, 2020. Disponível em: https://ir.netflix.net/.
16. Amazon Web Services. "Amazon DynamoDB—NoSQL Database Service." *AWS*, 2023. Disponível em: https://aws.amazon.com/dynamodb/.
17. Netflix Tech Blog. "Cassandra at Netflix." *Medium*, 2011. Disponível em: https://netflixtechblog.com/.
18. Corbett, J. C. et al. "Spanner: Google's Globally Distributed Database." *ACM Transactions on Computer Systems*, vol. 31, no. 3, 2013.
19. Uber Engineering. "Why Uber Engineering Switched from Postgres to MySQL." *Uber Engineering Blog*, 2016. Disponível em: https://eng.uber.com/mysql-migration/.

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

1) Trabalho executado no Google Colab - https://colab.research.google.com/drive/15iOpGMNPQulHNx4uDHvstKFQjhlXbboe?usp=sharing
2) Arquivo "Trabalho IAA011 - Execução Google Colab.pdf" em anexo com a execução em ambiente T4 do Google Colab;
3) Arquivo "lbp_train_features.csv" e "vgg_train_features.csv" em anexo, com as extrações de parâmetros;
4) Conclusão:

Extração de Características

O Random Forest demonstrou ser o modelo mais eficaz, sobretudo por ter apresentado os melhores índices de sensibilidade e especificidade entre os três avaliados. Isso reflete sua capacidade superior tanto em identificar corretamente os casos positivos quanto em minimizar os falsos positivos. Apesar de a RNA ter alcançado o melhor F1-Score, o Random Forest se destacou por proporcionar um desempenho mais uniforme e consistente nas três métricas consideradas.

Redes Neurais

O modelo VGG16, treinado sem a utilização de técnicas de Data Augmentation, mostrou-se extremamente eficiente conforme

demonstrado pela matriz de confusão. Esta matriz evidenciou um total de 369 previsões corretas de um universo de 371 possíveis.

A elevada especificidade do modelo indica uma eficácia notável em evitar falsos positivos. Por outro lado, a sensibilidade de 0.4973 sugere que o modelo foi capaz de reconhecer uma porção considerável dos exemplos verdadeiramente positivos.

Os resultados obtidos com o ResNet50 apontam para uma dificuldade do modelo em aprender a classificação. Diante disso, algumas estratégias poderiam ser adotadas para aprimorar o desempenho do modelo, tais como:

- Descongelar um número maior de camadas para permitir uma aprendizagem mais flexível;
- Incrementar o número de épocas para que o modelo tenha mais oportunidades de aprender com os dados;
- Realizar o balanceamento do conjunto de dados, a fim de evitar um viés do modelo em favor das classes mais frequentes;
- Garantir a qualidade dos dados, verificando se estão adequadamente formatados e rotulados, para assegurar a eficácia do treinamento do modelo.

1) Extração de características

```
[1]  import os
     import numpy as np
     import pandas as pd
     from sklearn.model_selection import train_test_split
     from sklearn.ensemble import RandomForestClassifier
     from sklearn.svm import SVC
     from sklearn.neural_network import MLPClassifier
     from sklearn.metrics import confusion_matrix, classification_report
     from keras.applications.vgg16 import VGG16
     from keras.preprocessing import image
     from keras.applications.vgg16 import preprocess_input
     from skimage.feature import local_binary_pattern
     from sklearn.preprocessing import LabelEncoder
     from sklearn.metrics import f1_score, recall_score, precision_score
     from sklearn import metrics
     import zipfile
     from keras.preprocessing.image import img_to_array, load_img
     import numpy as np
     from sklearn.model_selection import train_test_split
     import cv2
     from google.colab.patches import cv2_imshow
```

Preparação da base

```
train_zip_path = '/content/Train_Warwick.zip'
test_zip_path = '/content/Test_Warwick.zip'

train_extract_dir = '/content/Train_Warwick'
test_extract_dir = '/content/Test_Warwick'

def unzip_file(zip_path, extract_dir):
    with zipfile.ZipFile(zip_path, 'r') as zip_ref:
        zip_ref.extractall(extract_dir)

unzip_file(train_zip_path, train_extract_dir)
unzip_file(test_zip_path, test_extract_dir)

train_dir_contents = os.listdir(train_extract_dir)
test_dir_contents = os.listdir(test_extract_dir)

train_image_dir = os.path.join(train_extract_dir, 'Train_4cls_amostra')
test_image_dir = os.path.join(test_extract_dir, 'Test_4cl_amostra')

train_files = os.listdir(train_image_dir)
test_files = os.listdir(test_image_dir)

train_dir_contents, test_dir_contents

# Verificar a estrutura dentro dos diretórios de treino e teste
train_image_dir = os.path.join(train_extract_dir, 'Train_4cls_amostra')
test_image_dir = os.path.join(test_extract_dir, 'Test_4cl_amostra')

train_files = os.listdir(train_image_dir)
test_files = os.listdir(test_image_dir)

# Exibir os primeiros arquivos encontrados
train_files, test_files
```

```
(['1', '0', '3', '2'], ['1', '2_teste.txt', '0', '3', '2'])
```

1. Carregar base

```
# Função para carregar as imagens usando OpenCV
def load_images_opencv(base_dir):
    images = []
    labels = []
    for label_dir in os.listdir(base_dir):
        label_path = os.path.join(base_dir, label_dir)
        if os.path.isdir(label_path):  # Verificar se é um diretório de classe
            for img_file in os.listdir(label_path):
                if img_file.endswith('.png'):
                    img_path = os.path.join(label_path, img_file)
                    img = cv2.imread(img_path)
                    img = cv2.resize(img, (250, 250))
                    images.append(img)
                    labels.append(label_dir)  # O nome do diretório é o rótulo
    return np.array(images), np.array(labels)
```

```
# Carregar as imagens e rótulos do conjunto de treino e teste
train_images, train_labels = load_images_opencv(train_image_dir)
test_images, test_labels = load_images_opencv(test_image_dir)

# Exibir o tamanho das bases carregadas
train_images.shape, len(train_labels), test_images.shape, len(test_labels)

#Exibir amostra
cv2_imshow(train_images[1])
cv2_imshow(train_images[2])
cv2_imshow(train_images[3])
```

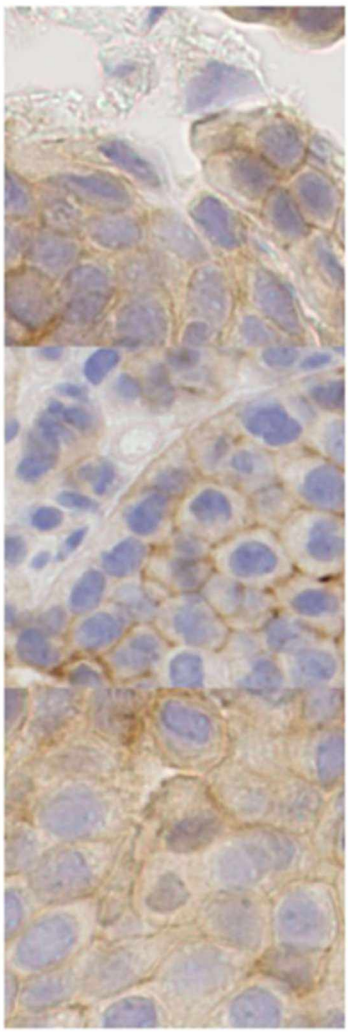

2. Criar partições 80/20

```
# Garantir que a separação seja feita por paciente
unique_patients = np.unique(train_labels)

# Separar 80% para treino e 20% para validação, garantindo a separação por paciente
train_patients, val_patients = train_test_split(unique_patients, test_size=0.2, random_state=42)

# Criar índices de treino e validação com base nos pacientes
train_idx = [i for i, label in enumerate(train_labels) if label in train_patients]
val_idx = [i for i, label in enumerate(train_labels) if label in val_patients]

# Criar os conjuntos de treino e validação
X_train, y_train = train_images[train_idx], train_labels[train_idx]
X_val, y_val = train_images[val_idx], train_labels[val_idx]

# Exibir o tamanho dos conjuntos de treino e validação
X_train.shape, len(y_train), X_val.shape, len(y_val)
```

```
((446, 250, 250, 3), 446, (147, 250, 250, 3), 147)
```

3. Extrai características utilizando LBP e a CNN VGG16 (gerando um csv para cada extrator)

4. Treine modelos Random Forest, SVM e RNA para predição dos dados extraídos

```python
def extract_lbp_features(images):
    lbp_features = []
    for img in images:
        gray_img = cv2.cvtColor(img.astype('uint8'), cv2.COLOR_BGR2GRAY)
        lbp = local_binary_pattern(gray_img, 24, 3, method="uniform")
        hist, _ = np.histogram(lbp.ravel(), bins=np.arange(0, 27), range=(0, 26))
        hist = hist.astype('float')
        hist /= (hist.sum() + 1e-6)  # Normalização
        lbp_features.append(hist)
    return np.array(lbp_features)

def extract_vgg16_features(images):
    vgg_model = VGG16(weights='imagenet', include_top=False)
    features = vgg_model.predict(images)
    features = features.reshape(features.shape[0], -1)  # Flatten
    return features

# Extração para treino
lbp_train_features = extract_lbp_features(X_train)
vgg_train_features = extract_vgg16_features(X_train)

# Extração para validação
lbp_val_features = extract_lbp_features(X_val)
vgg_val_features = extract_vgg16_features(X_val)

# Salvar como CSV
pd.DataFrame(lbp_train_features).to_csv('lbp_train_features.csv')
pd.DataFrame(vgg_train_features).to_csv('vgg_train_features.csv')
```

```
Downloading data from https://storage.googleapis.com/tensorflow/keras-applications/vgg16/vgg16_weights_tf_dim_ordering_tf_kernels_notop.h5
58889256/58889256 ━━━━━━━━━━━━━━━━━━━━ 4s 0us/step
14/14 ━━━━━━━━━━━━━━━━━━━━ 37s 1s/step
5/5 ━━━━━━━━━━━━━━━━━━━━ 15s 4s/step
```

```python
def avg_specificity(confusion_matrix):
    num_classes = confusion_matrix.shape[0]
    specificities = []

    for i in range(num_classes):
        # Verdadeiros Negativos (VN) são todos os valores fora da linha e coluna da classe i
        true_negatives = np.sum(confusion_matrix) - (np.sum(confusion_matrix[i, :]) + np.sum(confusion_matrix[:, i]) - confusion_matrix[i, i])
        # Falsos Positivos (FP) são a soma dos valores na coluna da classe i, exceto a diagonal (falsos positivos)
        false_positives = np.sum(confusion_matrix[:, i]) - confusion_matrix[i, i]

        # Evitar divisão por zero
        if (true_negatives + false_positives) > 0:
            specificity = true_negatives / (true_negatives + false_positives)
        else:
            specificity = 0  # Definir como 0 quando o denominador for 0
        specificities.append(specificity)

    # Especificidade média
    specificity_mean = np.mean(specificities)
    return specificity_mean
```

```
def train_and_evaluate(model, X_train, y_train, X_val, y_val):
    model.fit(X_train, y_train)
    y_pred = model.predict(X_val)
    cm = confusion_matrix(y_val, y_pred)
    sensitivity = recall_score(y_val, y_pred, average='macro')
    specificity = avg_specificity(cm)
    f1 = f1_score(y_val, y_pred, average='macro')
    return sensitivity, specificity, f1

# Modelos
rf_model = RandomForestClassifier()
svm_model = SVC()
rna_model = MLPClassifier()

train_and_evaluate(rf_model, vgg_train_features, y_train, vgg_val_features, y_val)
train_and_evaluate(svm_model, vgg_train_features, y_train, vgg_val_features, y_val)
train_and_evaluate(rna_model, vgg_train_features, y_train, vgg_val_features, y_val)
```

```
/usr/local/lib/python3.10/dist-packages/sklearn/metrics/_classification.py:1531: UndefinedMetricWarning: Recall is ill-defined and being set to 0.0 in labels with no true sa
  _warn_prf(average, modifier, f"{metric.capitalize()} is", len(result))
/usr/local/lib/python3.10/dist-packages/sklearn/metrics/_classification.py:1531: UndefinedMetricWarning: Recall is ill-defined and being set to 0.0 in labels with no true sa
  _warn_prf(average, modifier, f"{metric.capitalize()} is", len(result))
/usr/local/lib/python3.10/dist-packages/sklearn/metrics/_classification.py:1531: UndefinedMetricWarning: Recall is ill-defined and being set to 0.0 in labels with no true sa
  _warn_prf(average, modifier, f"{metric.capitalize()} is", len(result))
(0.0, 0.5, 0.0)
```

5. Carrega a base de teste e execute a tarefa 3 nesta base

```
lbp_test_features = extract_lbp_features(test_images)
vgg_test_features = extract_vgg16_features(test_images)
```

```
WARNING:tensorflow:5 out of the last 20 calls to <function TensorFlowTrainer.make_predict_function.<locals>.one_step_on_data_distributed at 0x7abcf097cdc0> triggered tf.func
12/12 ━━━━━━━━━━━━━━━━━━━━ 3s 213ms/step
```

6 e 7. Aplicação dos modelos treinados nos dados de teste e calculo das métricas de Sensibilidade, Especificidade e F1-Score

```
rf_test_sens, rf_test_spec, rf_test_f1 = train_and_evaluate(rf_model, vgg_train_features, y_train, vgg_test_features, test_labels)
svm_test_sens, svm_test_spec, svm_test_f1 = train_and_evaluate(svm_model, vgg_train_features, y_train, vgg_test_features, test_labels)
rna_test_sens, rna_test_spec, rna_test_f1 = train_and_evaluate(rna_model, vgg_train_features, y_train, vgg_test_features, test_labels)

print(f"Random Forest - Teste Sensibilidade: {rf_test_sens}, Especificidade: {rf_test_spec}, F1-Score: {rf_test_f1}")
print(f"SVM - Teste Sensibilidade: {svm_test_sens}, Especificidade: {svm_test_spec}, F1-Score: {svm_test_f1}")
print(f"RNA - Teste Sensibilidade: {rna_test_sens}, Especificidade: {rna_test_spec}, F1-Score: {rna_test_f1}")
```

```
Random Forest - Teste Sensibilidade: 0.7194444444444444, Especificidade: 0.9084025306445235, F1-Score: 0.6268723377755636
SVM - Teste Sensibilidade: 0.6944444444444444, Especificidade: 0.9003229207855543, F1-Score: 0.6037909171630103
RNA - Teste Sensibilidade: 0.7123212321232123, Especificidade: 0.9073283247660472, F1-Score: 0.6319611799889666
```

8. Melhor modelo baseado no f1

```
models = {'Random Forest': rf_test_f1, 'SVM': svm_test_f1, 'RNA': rna_test_f1}
best_model = max(models, key=models.get)
print(f"O melhor modelo foi {best_model} com F1-Score de {models[best_model]}")
```

```
O melhor modelo foi RNA com F1-Score de 0.6319611799889666
```

2) Redes Neurais

```
from keras.applications.vgg16 import VGG16
from keras.applications.resnet import ResNet50
from keras.layers import Dense, Flatten, GlobalAveragePooling2D
from keras.models import Model
from keras.optimizers import Adam
from tensorflow.keras.preprocessing.image import ImageDataGenerator

import warnings
warnings.filterwarnings('ignore')
```

1. Utilize a base de dados de Treino já separadas em treino e validação do exercício anterior (Resize de imagem para 224,224)

```
def resize_images(images):
    resized_images = []
    for img in images:
        resized_img = cv2.resize(img, (224, 224))  # Redimensionar para 224x224
        if img.shape[-1] == 1:  # Se a imagem tiver um único canal (em tons de cinza), converte para 3 canais
            resized_img = cv2.cvtColor(resized_img, cv2.COLOR_GRAY2RGB)
        resized_images.append(resized_img)
    return np.array(resized_images)

# Carregar as imagens e rótulos do conjunto de treino e validação
X_train_resized = resize_images(X_train)  # De 250x250 para 224x224
X_val_resized = resize_images(X_val)
X_test_resized = resize_images(test_images)

# Verificar as formas das imagens redimensionadas
print("Forma das imagens de treino:", X_train_resized.shape)
print("Forma das imagens de validação:", X_val_resized.shape)
print("Forma das imagens de teste:", X_test_resized.shape)
```

```
Forma das imagens de treino: (446, 224, 224, 3)
Forma das imagens de validação: (147, 224, 224, 3)
Forma das imagens de teste: (371, 224, 224, 3)
```

2. Treina modelos VGG16 e Resnet50 adaptadas com e sem Data Augmentation. Aplicando

```
# Verificar os rótulos e garantir que há 4 classes
print(np.unique(y_train))

# One-hot encode dos rótulos com 4 classes (0, 1, 2, 3)
from sklearn.preprocessing import LabelBinarizer
lb = LabelBinarizer()
lb.fit([0, 1, 2, 3])  # Garantindo que 4 classes são configuradas corretamente
y_train_bin = lb.transform(y_train)
y_val_bin = lb.transform(y_val)
y_test_bin = lb.transform(test_labels)

# Verificar a forma dos rótulos binarizados
print("Forma dos rótulos de treino:", y_train_bin.shape)

# Função para criar o modelo baseado na VGG16 com camadas Fully Connected ajustadas
def create_vgg16_model():
    base_model = VGG16(weights='imagenet', include_top=False, input_shape=(224, 224, 3))
    x = base_model.output
    x = Flatten()(x)  # Usando a camada Flatten para achatar as saídas
    x = Dense(128, activation='relu')(x)
    predictions = Dense(4, activation='softmax')(x)  # Ajustar para 4 classes
    model = Model(inputs=base_model.input, outputs=predictions)

    # Congelar as camadas da base da VGG16
    for layer in base_model.layers:
        layer.trainable = False

    model.compile(optimizer=Adam(), loss='categorical_crossentropy', metrics=['accuracy'])
    return model
```

```
# Função para criar o modelo baseado na ResNet50 com camadas Fully Connected ajustadas
def create_resnet50_model():
    base_model = ResNet50(weights='imagenet', include_top=False, input_shape=(224, 224, 3))
    x = base_model.output
    x = GlobalAveragePooling2D()(x)  # Usando GlobalAveragePooling2D em vez de Flatten
    x = Dense(128, activation='relu')(x)
    predictions = Dense(4, activation='softmax')(x)  # Ajustar para 4 classes
    model = Model(inputs=base_model.input, outputs=predictions)

    # Congelar as camadas da base da ResNet50
    for layer in base_model.layers:
        layer.trainable = False

    model.compile(optimizer=Adam(), loss='categorical_crossentropy', metrics=['accuracy'])
    return model
```

```python
# Função para treinar o modelo com ou sem Data Augmentation
def train_model(model, X_train, y_train, X_val, y_val, augment=False):
    if augment:
        datagen = ImageDataGenerator(
            rotation_range=20,
            width_shift_range=0.2,
            height_shift_range=0.2,
            horizontal_flip=True
        )
        datagen.fit(X_train)
        history = model.fit(datagen.flow(X_train, y_train, batch_size=32),
                            validation_data=(X_val, y_val),
                            epochs=10)
    else:
        history = model.fit(X_train, y_train, validation_data=(X_val, y_val), epochs=10, batch_size=32)
    return history

# Criar os modelos
vgg16_model = create_vgg16_model()
resnet50_model = create_resnet50_model()

# Treinar o modelo VGG16 sem Data Augmentation
print("Treinando VGG16 sem Data Augmentation...")
train_model(vgg16_model, X_train_resized, y_train_bin, X_val_resized, y_val_bin, augment=False)

# Treinar o modelo VGG16 com Data Augmentation
print("Treinando VGG16 com Data Augmentation...")
train_model(vgg16_model, X_train_resized, y_train_bin, X_val_resized, y_val_bin, augment=True)

# Treinar o modelo ResNet50 sem Data Augmentation
print("Treinando ResNet50 sem Data Augmentation...")
train_model(resnet50_model, X_train_resized, y_train_bin, X_val_resized, y_val_bin, augment=False)

# Treinar o modelo ResNet50 com Data Augmentation
print("Treinando ResNet50 com Data Augmentation...")
train_model(resnet50_model, X_train_resized, y_train_bin, X_val_resized, y_val_bin, augment=True)
```

```
14/14 ━━━━━━━━━━━━━━━━━━━━ 10s 491ms/step - accuracy: 0.2924 - loss: 0.0000e+00 - val_accuracy: 0.5578 - val_loss: 0.0000e+00
Epoch 4/10
14/14 ━━━━━━━━━━━━━━━━━━━━ 7s 292ms/step - accuracy: 0.3000 - loss: 0.0000e+00 - val_accuracy: 0.0000e+00 - val_loss: 0.0000e+00
Epoch 5/10
14/14 ━━━━━━━━━━━━━━━━━━━━ 11s 293ms/step - accuracy: 0.1945 - loss: 0.0000e+00 - val_accuracy: 1.0000 - val_loss: 0.0000e+00
Epoch 6/10
14/14 ━━━━━━━━━━━━━━━━━━━━ 10s 546ms/step - accuracy: 0.4125 - loss: 0.0000e+00 - val_accuracy: 0.8163 - val_loss: 0.0000e+00
Epoch 7/10
14/14 ━━━━━━━━━━━━━━━━━━━━ 10s 360ms/step - accuracy: 0.2654 - loss: 0.0000e+00 - val_accuracy: 0.9320 - val_loss: 0.0000e+00
Epoch 8/10
14/14 ━━━━━━━━━━━━━━━━━━━━ 8s 351ms/step - accuracy: 0.2380 - loss: 0.0000e+00 - val_accuracy: 0.0000e+00 - val_loss: 0.0000e+00
Epoch 9/10
14/14 ━━━━━━━━━━━━━━━━━━━━ 12s 323ms/step - accuracy: 0.2230 - loss: 0.0000e+00 - val_accuracy: 0.0000e+00 - val_loss: 0.0000e+00
Epoch 10/10
14/14 ━━━━━━━━━━━━━━━━━━━━ 8s 401ms/step - accuracy: 0.2371 - loss: 0.0000e+00 - val_accuracy: 1.0000 - val_loss: 0.0000e+00
Treinando ResNet50 sem Data Augmentation...
Epoch 1/10
14/14 ━━━━━━━━━━━━━━━━━━━━ 20s 802ms/step - accuracy: 0.1393 - loss: 0.0000e+00 - val_accuracy: 0.0000e+00 - val_loss: 0.0000e+00
Epoch 2/10
14/14 ━━━━━━━━━━━━━━━━━━━━ 9s 139ms/step - accuracy: 0.0198 - loss: 0.0000e+00 - val_accuracy: 0.0000e+00 - val_loss: 0.0000e+00
Epoch 3/10
14/14 ━━━━━━━━━━━━━━━━━━━━ 2s 120ms/step - accuracy: 0.0098 - loss: 0.0000e+00 - val_accuracy: 0.0000e+00 - val_loss: 0.0000e+00
Epoch 4/10
14/14 ━━━━━━━━━━━━━━━━━━━━ 3s 121ms/step - accuracy: 0.0164 - loss: 0.0000e+00 - val_accuracy: 0.0000e+00 - val_loss: 0.0000e+00
Epoch 5/10
14/14 ━━━━━━━━━━━━━━━━━━━━ 2s 125ms/step - accuracy: 0.0068 - loss: 0.0000e+00 - val_accuracy: 0.0000e+00 - val_loss: 0.0000e+00
Epoch 6/10
14/14 ━━━━━━━━━━━━━━━━━━━━ 3s 140ms/step - accuracy: 0.0113 - loss: 0.0000e+00 - val_accuracy: 0.0000e+00 - val_loss: 0.0000e+00
Epoch 7/10
14/14 ━━━━━━━━━━━━━━━━━━━━ 2s 125ms/step - accuracy: 0.0215 - loss: 0.0000e+00 - val_accuracy: 0.0000e+00 - val_loss: 0.0000e+00
Epoch 8/10
14/14 ━━━━━━━━━━━━━━━━━━━━ 3s 127ms/step - accuracy: 0.0292 - loss: 0.0000e+00 - val_accuracy: 0.0000e+00 - val_loss: 0.0000e+00
Epoch 9/10
14/14 ━━━━━━━━━━━━━━━━━━━━ 2s 143ms/step - accuracy: 0.0164 - loss: 0.0000e+00 - val_accuracy: 0.0000e+00 - val_loss: 0.0000e+00
Epoch 10/10
14/14 ━━━━━━━━━━━━━━━━━━━━ 2s 144ms/step - accuracy: 0.0219 - loss: 0.0000e+00 - val_accuracy: 0.0000e+00 - val_loss: 0.0000e+00
Treinando ResNet50 com Data Augmentation...
Epoch 1/10
14/14 ━━━━━━━━━━━━━━━━━━━━ 19s 511ms/step - accuracy: 0.0693 - loss: 0.0000e+00 - val_accuracy: 0.0000e+00 - val_loss: 0.0000e+00
Epoch 2/10
14/14 ━━━━━━━━━━━━━━━━━━━━ 7s 307ms/step - accuracy: 0.0841 - loss: 0.0000e+00 - val_accuracy: 0.0000e+00 - val_loss: 0.0000e+00
Epoch 3/10
14/14 ━━━━━━━━━━━━━━━━━━━━ 5s 229ms/step - accuracy: 0.0940 - loss: 0.0000e+00 - val_accuracy: 0.0000e+00 - val_loss: 0.0000e+00
Epoch 4/10
14/14 ━━━━━━━━━━━━━━━━━━━━ 15s 346ms/step - accuracy: 0.0984 - loss: 0.0000e+00 - val_accuracy: 0.0000e+00 - val_loss: 0.0000e+00
Epoch 5/10
14/14 ━━━━━━━━━━━━━━━━━━━━ 10s 253ms/step - accuracy: 0.1469 - loss: 0.0000e+00 - val_accuracy: 0.0000e+00 - val_loss: 0.0000e+00
Epoch 6/10
14/14 ━━━━━━━━━━━━━━━━━━━━ 9s 384ms/step - accuracy: 0.1098 - loss: 0.0000e+00 - val_accuracy: 0.0000e+00 - val_loss: 0.0000e+00
Epoch 7/10
14/14 ━━━━━━━━━━━━━━━━━━━━ 8s 253ms/step - accuracy: 0.1078 - loss: 0.0000e+00 - val_accuracy: 0.0000e+00 - val_loss: 0.0000e+00
Epoch 8/10
14/14 ━━━━━━━━━━━━━━━━━━━━ 10s 254ms/step - accuracy: 0.2165 - loss: 0.0000e+00 - val_accuracy: 0.0000e+00 - val_loss: 0.0000e+00
Epoch 9/10
14/14 ━━━━━━━━━━━━━━━━━━━━ 11s 237ms/step - accuracy: 0.1030 - loss: 0.0000e+00 - val_accuracy: 0.0000e+00 - val_loss: 0.0000e+00
Epoch 10/10
14/14 ━━━━━━━━━━━━━━━━━━━━ 6s 251ms/step - accuracy: 0.1683 - loss: 0.0000e+00 - val_accuracy: 0.0000e+00 - val_loss: 0.0000e+00
<keras.src.callbacks.history.History at 0x7abcbc25c250>
```

3. Aplique os modelos treinados nas imagens da base de Teste

4. Calcule as métricas de Sensibilidade, Especificidade e F1-Score com base em suas matrizes de confusão.

5. Indique qual modelo dá o melhor o resultado e a métrica utilizada

```python
def evaluate_model(model, X_test, y_test):
    y_pred = np.argmax(model.predict(X_test), axis=1)
    y_true = np.argmax(y_test, axis=1)

    # Identificar as classes presentes
    labels_present = np.unique(y_true)

    # Matriz de confusão
    cm = confusion_matrix(y_true, y_pred, labels=labels_present)
    print("Matriz de Confusão:")
    print(cm)

    # Relatório de classificação apenas para as classes presentes
    report = classification_report(y_true, y_pred, labels=labels_present, target_names=[str(l) for l in labels_present], zero_division=1)
    print(report)

    # Cálculo de Sensibilidade, Especificidade e F1-Score
    sensitivity = recall_score(y_true, y_pred, average='macro')
    specificity = np.mean(np.diag(cm) / np.sum(cm, axis=1))
    f1 = f1_score(y_true, y_pred, average='macro')

    return sensitivity, specificity, f1

# Avaliar os modelos na base de teste
print("Avaliando VGG16 sem Data Augmentation...")
vgg16_sens, vgg16_spec, vgg16_f1 = evaluate_model(vgg16_model, X_test_resized, y_test_bin)

print("Avaliando ResNet50 sem Data Augmentation...")
resnet50_sens, resnet50_spec, resnet50_f1 = evaluate_model(resnet50_model, X_test_resized, y_test_bin)

# Comparar os resultados
print(f"VGG16 - Sensibilidade: {vgg16_sens}, Especificidade: {vgg16_spec}, F1-Score: {vgg16_f1}")
print(f"ResNet50 - Sensibilidade: {resnet50_sens}, Especificidade: {resnet50_spec}, F1-Score: {resnet50_f1}")

# Comparar os modelos e exibir o melhor resultado
models = {'VGG16': vgg16_f1, 'ResNet50': resnet50_f1}
best_model = max(models, key=models.get)
print(f"O melhor modelo foi {best_model} com F1-Score de {models[best_model]}")
```

```
Avaliando VGG16 sem Data Augmentation...
12/12 ━━━━━━━━━━━━━━━━━━━━ 2s 183ms/step
Matriz de Confusão:
[[369]]
              precision    recall  f1-score   support

           0       1.00      0.99      1.00       371

   micro avg       1.00      0.99      1.00       371
   macro avg       1.00      0.99      1.00       371
weighted avg       1.00      0.99      1.00       371

Avaliando ResNet50 sem Data Augmentation...
12/12 ━━━━━━━━━━━━━━━━━━━━ 10s 348ms/step
Matriz de Confusão:
[[0]]
              precision    recall  f1-score   support

           0       1.00      0.00      0.00     371.0

   micro avg       1.00      0.00      0.00     371.0
   macro avg       1.00      0.00      0.00     371.0
weighted avg       1.00      0.00      0.00     371.0

VGG16 - Sensibilidade: 0.4973045822102426, Especificidade: 1.0, F1-Score: 0.49864864864864866
ResNet50 - Sensibilidade: 0.0, Especificidade: nan, F1-Score: 0.0
O melhor modelo foi VGG16 com F1-Score de 0.49864864864864866
```

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

1 INTRODUÇÃO

O serviço de chat, com respostas geradas por uma inteligência artificial, da Open AI, cresceu sua base de usuários de forma assustadoramente rápida. O Chat GPT (acrônimo de Chat Generative Pre-trained Transformer) foi liberado ao público em 2022 - sendo sua primeira versão privada criada em 2018 - e atingiu a marca de 1 milhão de usuários em apenas 5 dias (BUCHHOLZ, 2023). Em dois meses atingiu a marca de 100 milhões de usuários (HU, 2023). Tornando-se o serviço digital com a adesão mais rápida da história. Tamanha evolução causa riscos e preocupações éticas que não tínhamos até então nesta particular área do desenvolvimento de software. Urge a discussão dos efeitos causados na segurança, trabalho humano e atenção à discriminação e desigualdades sociais para que este desenvolvimento preserve os direitos fundamentais. E que seja assegurado desenvolvimento tecnológico seguro em benefício da pessoa humana.

No Brasil, tramita no Senado Federal a PL 2.338/2023 (BRASIL, 2023), texto inicial do Senador e presidente da casa Rodrigo Pacheco (PSD-MG), com a participação de uma comissão. Tal projeto de lei é considerado a primeira base para o Marco Legal da Inteligência Artificial no Brasil. Mas avança lentamente e as discussões parecem não ter eco nas empresas como fora o Marco Civil da Internet. Embora tenham realizado quatro audiências públicas, um seminário internacional, doze painéis temáticos e consulta a mais de 60 especialistas (BRASIL, 2023).

2 REVISÃO DE LITERATURA

2.1 RISCO DO USO EXCESSIVO

A motivação do uso massivo do Chat GPT, um LLM (Large Language Model) ou modelo de aprendizagem de máquina com bilhões de parâmetros, é bem clara. Conseguimos respostas rápidas para qualquer assunto, somos capazes de usá-lo para criar textos com estilos diversos, criar código de programação, traduzir documentos em idiomas diferentes, aprender sobre novos temas, obter insights de como resolver problemas, dos mais complexos aos mais frugais, como por resolver uma equação integral esférica para encontrar o volume de uma esfera imperfeita ou como trocar uma lâmpada de tungstênio.

Mas não se engane, como toda ferramenta, existem imperfeições, neste caso o termo usualmente utilizado para descrever estas imperfeições é alucinações. É quando o modelo de linguagem não consegue inferir uma resposta correta e acaba produzindo um texto falso, seja por vieses, poucos dados de treinamento ou overfitting, dos algoritmos. Emsley (2023) defende que não são alucinações e sim invenções e falsificações. Ele descreve a imperfeição como:

> *"A causa destas falsificações tem sido associada a uma perturbação na produção linguística, com resultados probabilísticos baseados em estimativas de similaridade semântica" - (EMSLEY,2023)*

Emsley (2023) cita que em uma investigação de acurácia e autenticidade de artigos médicos, o ChatGPT citou 115 referências. Destas 47% foram fabricadas, 46% são autênticas porém imprecisas e apenas 7% foi identificada como autêntica e precisa.

Em que nível está esta alucinação? Só recentemente a OpenAI adicionou o alerta que passa desapercebido pela maioria das pessoas: "ChatGPT pode cometer erros. Considere verificar informações importantes.". Mas não há monitoramento de sua qualidade. Fica evidente a necessidade de supervisão humana qualificada. E mais, conscientização de seu uso, dado que a confiabilidade na assertividade está ainda longe de ser uma constante.

Como toda ferramenta nova, seu uso intenso pode causar uma série de efeitos colaterais não conhecidos ou não relacionados ainda. Por exemplo, no início da revolução da comunicação causada pelos dispositivos móveis cada vez mais cheio de recursos, aliados à expansão da própria internet, os teclados destes dispositivos causaram surtos de problemas nos tendões, inflamação que recebeu o apelido de "BlackBerry Thumb". Embora tenha sido descoberta há anos com a alcunha de síndrome de Quervain (ORTHOPEDIC AND SPORTS SPECIALISTS, 2024), somente com a explosão massiva dos tecladinhos diminutos é que a síndrome foi experimentada massivamente.

A ansiedade humana da busca pelo conhecimento também viu na interconexão da internet, crises de ansiedade e doenças novas como a nomofobia (no mobile phobia), que é quando o indivíduo não consegue ficar longe do celular (YOUGOV, 2023). O uso massivo do assistente sugere que o caminho de novas doenças ou deficiências também seja trilhado. Por isso carece de estudo sério e de discussões a seu respeito, para que seja legislado sobre.

Vale ressaltar que a partir da versão 4-o do Chat GPT você pode conversar com a IA através do aplicativo móvel. O uso excessivo do assistente virtual sugere riscos nas relações humanas, uma vez que impreterivelmente podem ser substituídas em certo grau - o assistente lhe dá as respostas que você quer ouvir, reforçando suas crenças. Não estamos distantes do filme Her (HER, 2013), onde um escritor solitário chamado Theodore, se apaixona por um sistema operacional, cuja voz fora personificada como Samantha.

A modalidade do ensino remoto também já tem seus efeitos. Há estudos que indicam que os tempos de concentração são inferiores aos presenciais, tornando necessário intervenções regulares para garantir coesão (STROM et al., 2023). Agora mude para o cenário do Chat GPT. Entenda que neste estudo, você tenha à disposição algo que não só te indique o caminho como lhe responda de forma relativamente objetiva o que for perguntado. Ou que seja capaz de fazer a pesquisa por você. Mais do que um tutor, a IA se comporta como um parceiro de trabalho. Se o usuário não for consciente

dessas implicações e das limitações da ferramenta, as consequências podem ser ainda mais desastrosas no campo do aprendizado.

2.2 NEUTRALIDADE E REPRESENTATIVIDADE

Para dar respostas mais precisas, o modelo de aprendizagem de máquina não supervisionado é treinado com um grande volume de dados. De acordo com (BROWN et al, 2020), o Chat GPT versão 3 (175 bilhões de parâmetros) usou para ser treinado 8 anos de indexação de sites, publicações do serviço, publicações do serviço de forum Reddit com mais votos, bibliotecas de livros digitalizados - inclusive acadêmicos, e a versão em inglês da Wikipedia. Sendo que destes 93% dos dados estão no idioma inglês.

Na versão 4 do ChatGPT (MAZZONI et al., 2023), além de usar dados licenciados de provedores terceiros, o algoritmo consegue consultar dados públicos na internet. E usa um mecanismo chamado de Reinforcement Learning from Human Feedback (RLHF) para que a resposta seja direcionada para a pergunta do usuário (diretrizes ou limitações impostas ou user guardrails).

Com esta formulação é dificílimo pensar em representatividade de toda a diversidade cultural existente no mundo ou isonomia de pensamento, já que majoritariamente usa só o idioma de uma nação. Com uma base notavelmente focada na interpretação do mundo pela ótica dos Estados Unidos. É o viés consumado. Quase a garantia de amplificação de preconceitos existentes nesta sociedade. Uma ferramenta de perpetuação de injustiças e discriminações.

Não precisamos ir longe para traçar paralelos com o que já vivenciamos. Veja o caso do cinema nacional, que teve sua criatividade e pujança duramente ofuscadas pela massividade de produções cinematográficas norte-americanas. Não só como efeito de dominação cultural, mas também legislativa, dado que impreterivelmente privilegiava o estrangeiro com financiamentos vultosos. Tal situação foi denunciada, discutida, escrutinada por Paulo Emílio Gomes, no livro “Uma situação Colonial?” (Gomes, 2016). Uma das frases do autor marca a situação:

> *“O cinema é incapaz de encontrar dentro de si próprio, energias que lhe permitam escapar à condenação do subdesenvolvimento” (GOMES, 2016)*

Isto é, mesmo que o cinema nacional faça uma obra sui generis, o gosto do público já foi tomado pela outra cultura. E não há espaço ou valia no reconhecimento da própria identidade. Por outro ângulo, a questão da neutralidade, devemos ter a ciência de que a ferramenta não está disponível em todos os países do mundo. Seja pela legislação do país, seja por motivos puramente estratégicos, bélicos ou financeiros. Pelo site oficial é possível obter uma lista de países suportados (OPENAI, 2024). Nota-se a ausência de China, Rússia, Síria, Cuba, Coreia do Norte dentre outros. O ponto de análise é: se a IA aprende através de trocas de mensagens com os usuários e através de pesquisas em sites da internet, artificialmente (ou naturalmente, fosse um humano) aprenderá pouco da cultura Oriental - com a devida visão da origem. Suas inferências probabilísticas serão, portanto, apenas espelhos da realidade. Eventualmente reforçadores de estereótipos.

Não é difícil pensar também em diferentes manifestações de racismo. A geração de imagens, recurso do DALL-E, incorporado aos modelos do Chat GPT tem inúmeros casos de falta de representatividade. (NUNES, 2022) faz uma importante revelação ao testar a busca por termos como “homem foto” e “mulher foto” e contar as ocorrências. Os algoritmos de IA das buscas foram treinados para encontrar referências de homem e mulher brancos europeus. É o racismo estrutural sedimentado.

Nunes (2022) também cita (BUOLAMWINI, 2016), pesquisadora que criou a Algorithimc Justice League (ALGORITHMIC JUSTICE LEAGUE, 2024), para que algoritmos evitem vieses. Ela demonstrou em sua pesquisa no MIT Media Lab que os algoritmos foram treinados para identificar rostos de brancos. Ela percebeu que precisava usar uma máscara branca para ser identificada como humana por alguns softwares de identificação facial.

Extrapolando a ideia, se solicitar ao ChatGPT para gerar uma imagem de um casal, sem passar qualquer instrução que sugira diversidade, na maioria dos casos a imagem gerada será um casal branco. Não que ele tenha sido programado para isto, mas a questão do treinamento e dos dados utilizados acabam carregando os chamados vieses algorítmicos. Imagine que as empresas desenvolvam aplicações de classificação de pessoas para fornecer um empréstimo, por exemplo. O bem-estar estaria ameaçado.

2.3 TRANSPARÊNCIA

É muito claro que vivenciamos uma corrida para melhores modelos de IA generativa. Empresas como Microsoft, Open AI, Claude AI, Meta e outras, investem pesado a caminho de uma IA multimodal mais completa com capacidade cognitiva semelhante a humana, conhecida como IA Geral ou AGI. Mas as questões de transparência levantaram pressões internas nestas empresas. É tão crítico que funcionários e ex-funcionários da própria OpenAI e de outras empresas fronteiriças de IA, criaram uma carta aberta chamada Right to Warn AI. Na carta aberta (RIGHT TO WARN, 2024) deixam claro que as empresas têm fortes incentivos financeiros para evitar a supervisão eficaz.

Alegam ainda que as empresas possuem relatórios de falhas, de imprecisões, seus controles, riscos implícitos de seus processos e que estes não são públicos. As empresas têm pouca obrigação de partilhar estas informações com governos e sugere nas entrelinhas que as empresas não dão espaço para uma cultura aberta que fomente a discussão.

Para se ter uma ideia de precificação, o chat GPT gasta diariamente cerca de 700 mil dólares para funcionar (PATEL; AHMAD, 2023). Convertendo em reais, sem impostos, a soma passaria 1,384 bilhões de reais. Fora os custos de treinamento, licenciamento de conteúdo e demais custos operacionais.

Embora seja razoavelmente público que os primeiros modelos usaram anos de coleta de informações da internet, pouco se sabe a respeito dos métodos que foram usados na filtragem destes dados. Somente recentemente a Open AI lançou um programa de parceria de dados, o Open AI Data Partnerships (OPENAI, 2024). E através dele fez parcerias com o governo da Islândia e com uma instituição sem fins lucrativos chamada FreeLaw para usar sua base de casos jurídicos no treinamento. São bases tratadas e revisadas.

2.4 PRIVACIDADE DOS DADOS

Desde o Chat GPT versão 2, o serviço de chat utiliza um mecanismo de aprendizagem por reforço com recompensas a partir das perguntas dos humanos (ZIEGLER et al., 2019). Para isso o histórico de uso é armazenado e o perfil do usuário vai sendo aos poucos traçados.

Em 2023, o serviço de proteção a dados da Itália bloqueou o serviço de chatbot pelo não cumprimento das normas estabelecidas pela GDPR (General Data Protection Regulation), dado que não havia naquele tempo tratamento adequado a adolescentes abaixo de 13 anos. E mais grave, detectaram que até 1,2% de dados pessoais de um indivíduo poderiam vazar para outro usuário do sistema.

Controles foram estabelecidos para que o histórico de conversas seja desabilitado e dados pessoais possam não só ser exportados, com limpos. Além de um parco controle de acesso a menores de idade. Mas ainda é questionável a qualidade destas proteções, dado que os controles são ativados por padrão – e a maioria dos usuários nem se dá conta disso.

Existem estudos como o de (LIU et al., 2023), que demonstram de forma empírica prompts que conseguiram liberar todas as restrições do modelo de linguagem. A preocupação excessiva com vazamentos não parece ser infundada portanto.

3 METODOLOGIA

Com todas estas questões analisadas, criamos um questionário qualitativo para avaliar como o uso nas empresas tem se dado. O questionário foi disparado para grupos de entusiastas de IA e profissionais da computação que trabalham em áreas diversas.

As questões do questionário foram:

1. Como que frequência você usa IA em seu contexto de trabalho?
2. Você acredita que a sua organização tem políticas suficientes para evitar o uso excessivo de IA?
3. Na sua opinião, a IA utilizada pela sua organização é neutra e imparcial?
4. Sua empresa toma medidas para garantir que os dados utilizados para treinar modelos de IA sejam representativos da diversidade da população?
5. A sua organização informa claramente aos usuários sobre o uso de IA em seus serviços/produtos?
6. . Os algoritmos e processos de decisão da IA são acessíveis e compreensíveis para os funcionários?
7. Você considera que a sua empresa está em conformidade com as regulamentações de privacidade de dados ao usar IA?

8. A sua organização possui uma estrutura clara de accountability para o uso de IA?
9. Quem é responsável por monitorar e garantir a ética na utilização de IA em sua empresa?
10. Quais procedimentos são seguidos quando ocorre um erro significativo em um sistema de IA?

4 APRESENTAÇÃO DOS RESULTADOS

Embora os resultados não tenham sido em grande volume – apenas 17 respostas - para que a amostra seja considerada, ela fornece preciosos insights de como as empresas estão em sua maioria despreparadas para o uso equalitário e responsável.

47,1% das respostas afirmam que utilizam muito frequentemente o IA em suas empresas. Mas 35,3% deles não acreditam que a empresa tenha política para evitar o uso excessivo. Outros 35,3% acreditam que a empresa tem parcialmente política para evitar o uso excessivo. Apenas 23,5% acreditam que o algoritmo de IA é imparcial ou neutro. Apenas 29,5% afirmam que as empresas tomam sempre medidas para que os modelos sejam representativos da diversidade populacional.

47,1% das empresas informam claramente seus usuários sobre o uso de IA em seus produtos. Mas 11,8% das empresas nunca informam.

Apenas 29,5% acreditam que a IA das empresas são acessíveis e compreensíveis para todos os funcionários.

O único ponto positivo da pesquisa é que 47,1% das pessoas acreditam que suas empresas estão em conformidade de privacidade de dados. Mas 35,3% não sabem se a empresa tem alguma estrutura clara de prestação de contas para o uso de IA. Em geral a área de TI ou de Compliance absorve a responsabilidade pelo uso ético.

5 CONSIDERAÇÕES FINAIS

Ao adotarmos o Chat GPT para as atividades cotidianas, possibilitamos a automação de tarefas e a substituição de funções, o que pode reduzir a necessidade de força de trabalho humana. É crucial examinarmos as implicações dessas mudanças. Para mitigar os impactos negativos, devemos equilibrar e, se necessário, restringir o uso da IA assegurando a proteção dos direitos individuais, a promoção da transparência e da responsabilidade, a prevenção de discriminação e viés, e a preservação da autonomia e dignidade humanas.

Recomendamos que as empresas e a sociedade civil criem ambientes que fomentem discussões de forma constante, para que o uso de IA respeite os seguintes pontos:

Neutralidade Algorítmica: Criar algoritmos que evitem preconceitos e discriminações, sendo desenvolvidos e implementados com esse propósito;

Transparência: Prover explicações claras sobre o processo de coleta, armazenamento e utilização de dados, assim como os critérios e mecanismos de decisão dos algoritmos;

Prestação de Contas (Accountability): Implementar mecanismos efetivos de responsabilização, com auditorias e avaliações éticas;

Proteção da Privacidade: Adotar políticas rigorosas para a proteção de dados pessoais, assegurando que a coleta e uso de dados sejam éticos e seguros, com respeito à privacidade dos usuários, e fomentar o debate público sobre essas práticas;

Equidade e Justiça: Garantir que as decisões automatizadas sejam justas e equitativas, evitando discriminações de qualquer natureza, como racial, de gênero ou por origem, através da implementação de critérios transparentes e auditáveis, com a devida informação ao usuário;

Inovação Responsável: Fomentar o desenvolvimento de IA que respeite os direitos e valores democráticos, promovendo uma inovação tecnológica responsável e sustentável;

Conformidade com Regulamentações: Garantir que o desenvolvimento e uso da IA estejam em conformidade com as regulamentações vigentes, incluindo leis de proteção de dados e direitos individuais, o marco civil da internet, a lei geral de proteção aos dados e as cláusulas pétreas da constituição;

Conscientização: Criar e distribuir materiais que esclareçam os riscos e ofereçam recomendações para o uso racional das ferramentas de IA.

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

Aluna/o:	Marcelo Silva da Silva
Nome do artigo escolhido:	Architecting ML-enabled systems: Challenges, best practices, and design decisions

Qual o **objetivo** do estudo descrito pelo artigo?	Qual o **problema/oportunidade/situação** que levou à necessidade de realização desse estudo?	Qual a **metodologia** que os autores usaram para obter e analisar as informações do estudo?	Quais os **principais resultados** obtidos pelo estudo?
O objetivo é identificar desafios comuns, melhores práticas de design e principais decisões de design e arquitetura de software para aprendizado de máquina. Sendo desdobrado/Refinado em tópicos de pesquisa: 1. Quais são os desafios de design de arquitetura de software mais comuns em sistemas habilitados para ML? 2. Quais são as melhores práticas na arquitetura de sistemas habilitados para ML 3. Quais são as principais decisões de design de arquitetura de software para sistemas habilitados para ML?	Seria implementar/habilitar arquiteturas eficazes para atender os desafios de criar algoritmos de ML que atendam as necessidades complexas de sistemas de recomendação, sistemas autônomos, assistentes inteligentes e outras aplicações.	Foi um método misto, incluindo revisão sistemática da literatura e entrevistas com especialistas. Aplicando metodologia de gerenciamento de projeto nas etapas: 1. Planning 2. Conducting 3. Documenting Estruturando a pesquisa (Criando os questionários), fazendo as entrevistas, extraindo os dados, fazendo as análises dos dados quantitativas e qualitativas. Ao final foi gerado um resumo das conclusões agrupando em seis categorias arquitetura, dados, evolução, controle de qualidade, modelo e SDLC.	Identificamos 35 desafios de design, 42 práticas recomendadas e 27 decisões de design ao arquitetar sistemas de aprendizado de máquina. Ao eliciar os principais desafios de design, contribuímos para as melhores práticas e decisões de design. Além disso, identificamos correlações entre desafios de design, decisões e melhores práticas.

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

1) RNA Classificação (Fashion)

```
[ ] #Bibliotecas

    import tensorflow as tf
    import matplotlib.pyplot as plt
    import numpy as np

    from sklearn.model_selection import train_test_split
    from sklearn.preprocessing import StandardScaler
    from mlxtend.plotting import plot_confusion_matrix
    from sklearn.metrics import confusion_matrix
```

```
    # Carregando base https://www.tensorflow.org/datasets/catalog/fashion_mnist?hl=pt-br

    data = tf.keras.datasets.fashion_mnist.load_data()

    (x_train, y_train), (x_test, y_test) = data

    x_data = np.concatenate([x_train, x_test])
    y_data = np.concatenate([y_train, y_test])

    # Split  75% treinamento e 25% teste
    x_train, x_test, y_train, y_test = train_test_split(
        x_data, y_data, test_size=0.3, random_state=42
    )
```

```
    # Número de linhas e colunas
    print("x_train shape:", x_train.shape)
    print("y_train shape:", y_train.shape)
    print("x_test shape:", x_test.shape)
    print("y_test shape:", y_test.shape)

    #Exemplo dos dados
    print(x_train)
```

```
x_train shape: (49000, 28, 28)
y_train shape: (49000,)
x_test shape: (21000, 28, 28)
y_test shape: (21000,)
[[[0 0 0 ... 0 0 0]
  [0 0 0 ... 0 0 0]
  [0 0 0 ... 0 0 0]
  ...
  [0 0 0 ... 0 0 0]
  [0 0 0 ... 0 0 0]
  [0 0 0 ... 0 0 0]]

 [[0 0 0 ... 0 0 0]
  [0 0 0 ... 0 0 0]
  [0 0 0 ... 0 0 0]
  ...
  [0 0 0 ... 0 0 0]
  [0 0 0 ... 0 0 0]
  [0 0 0 ... 0 0 0]]

 [[0 0 0 ... 0 0 0]
  [0 0 0 ... 0 0 0]
  [0 0 0 ... 0 0 0]
  ...
  [0 0 0 ... 0 0 0]
  [0 0 0 ... 0 0 0]
  [0 0 0 ... 0 0 0]]

 ...

 [[0 0 0 ... 0 0 0]
  [0 0 0 ... 0 0 0]
  [0 0 0 ... 0 0 0]
  ...
  [0 0 0 ... 0 0 0]
  [0 0 0 ... 0 0 0]
  [0 0 0 ... 0 0 0]]

 [[0 0 0 ... 0 0 0]
  [0 0 0 ... 0 0 0]
  [0 0 0 ... 0 0 0]
  ...
  [0 0 0 ... 0 0 0]
  [0 0 0 ... 0 0 0]
  [0 0 0 ... 0 0 0]]

 [[0 0 0 ... 0 0 0]
  [0 0 0 ... 0 0 0]
  [0 0 0 ... 0 0 0]
  ...
  [0 0 0 ... 0 0 0]
  [0 0 0 ... 0 0 0]
  [0 0 0 ... 0 0 0]]]
```

```
#Normalização dos pixels

x_train = x_train / 255.0
x_test = x_test / 255.0
```

```
#Criação do modelo

model = tf.keras.models.Sequential([
    tf.keras.layers.Flatten(input_shape=(28, 28)),
    tf.keras.layers.Dense(128, activation='relu'),
    tf.keras.layers.Dense(10, activation='softmax')
])
```

```
#Otimização do modelo com gradiente descendente, avaliando com acurácia
#OBS: A função de perda escolhida é mais adequada a problemas de classificação, quando o índice é inteiro e representa a classe


model.compile(optimizer='adam',
              loss='sparse_categorical_crossentropy',
              metrics=['accuracy'])
```

```
# Treinamento com 10 épocas

history = model.fit(x_train, y_train, epochs=10, validation_data=(x_test, y_test))
```

```
Epoch 1/10
1532/1532 ━━━━━━━━━━━━━━━━━━━━ 10s 5ms/step - accuracy: 0.7703 - loss: 0.6625 - val_accuracy: 0.8480 - val_loss: 0.4238
Epoch 2/10
1532/1532 ━━━━━━━━━━━━━━━━━━━━ 7s 3ms/step - accuracy: 0.8562 - loss: 0.4060 - val_accuracy: 0.8621 - val_loss: 0.3768
Epoch 3/10
1532/1532 ━━━━━━━━━━━━━━━━━━━━ 7s 4ms/step - accuracy: 0.8704 - loss: 0.3592 - val_accuracy: 0.8693 - val_loss: 0.3607
Epoch 4/10
1532/1532 ━━━━━━━━━━━━━━━━━━━━ 11s 5ms/step - accuracy: 0.8818 - loss: 0.3254 - val_accuracy: 0.8709 - val_loss: 0.3496
Epoch 5/10
1532/1532 ━━━━━━━━━━━━━━━━━━━━ 7s 4ms/step - accuracy: 0.8878 - loss: 0.3057 - val_accuracy: 0.8709 - val_loss: 0.3460
Epoch 6/10
1532/1532 ━━━━━━━━━━━━━━━━━━━━ 9s 4ms/step - accuracy: 0.8906 - loss: 0.2961 - val_accuracy: 0.8790 - val_loss: 0.3352
Epoch 7/10
1532/1532 ━━━━━━━━━━━━━━━━━━━━ 12s 5ms/step - accuracy: 0.8987 - loss: 0.2701 - val_accuracy: 0.8669 - val_loss: 0.3686
Epoch 8/10
1532/1532 ━━━━━━━━━━━━━━━━━━━━ 6s 4ms/step - accuracy: 0.8995 - loss: 0.2670 - val_accuracy: 0.8768 - val_loss: 0.3354
Epoch 9/10
1532/1532 ━━━━━━━━━━━━━━━━━━━━ 13s 6ms/step - accuracy: 0.9058 - loss: 0.2552 - val_accuracy: 0.8851 - val_loss: 0.3178
Epoch 10/10
1532/1532 ━━━━━━━━━━━━━━━━━━━━ 11s 6ms/step - accuracy: 0.9077 - loss: 0.2413 - val_accuracy: 0.8921 - val_loss: 0.2994
```

```
#Checando resultados
print("Pontuação de treinamento: ", model.evaluate(x_train,y_train))
print("Pontuação de teste: ", model.evaluate(x_test, y_test))
```

```
1532/1532 ━━━━━━━━━━━━━━━━━━━━ 3s 2ms/step - accuracy: 0.9210 - loss: 0.2159
Pontuação de treinamento:  [0.21703098714351654, 0.9197347164154053]
657/657 ━━━━━━━━━━━━━━━━━━━━ 1s 1ms/step - accuracy: 0.8954 - loss: 0.2966
Pontuação de teste:  [0.2994283437728882, 0.892142832792053]
```

```
# Gráficos durante o treinamento

plt.plot(history.history['accuracy'])
plt.plot(history.history['val_accuracy'])
plt.title('Acurácia do Modelo')
plt.ylabel('Acurácia')
plt.xlabel('Época')
plt.legend(['Treino', 'Validação'], loc='upper left')
plt.show()


plt.plot(history.history['loss'])
plt.plot(history.history['val_loss'])
plt.title('Perda do modelo')
plt.ylabel('Perda')
plt.xlabel('Época')
plt.legend(['Treino', 'Validação'], loc='upper left')
plt.show()
```

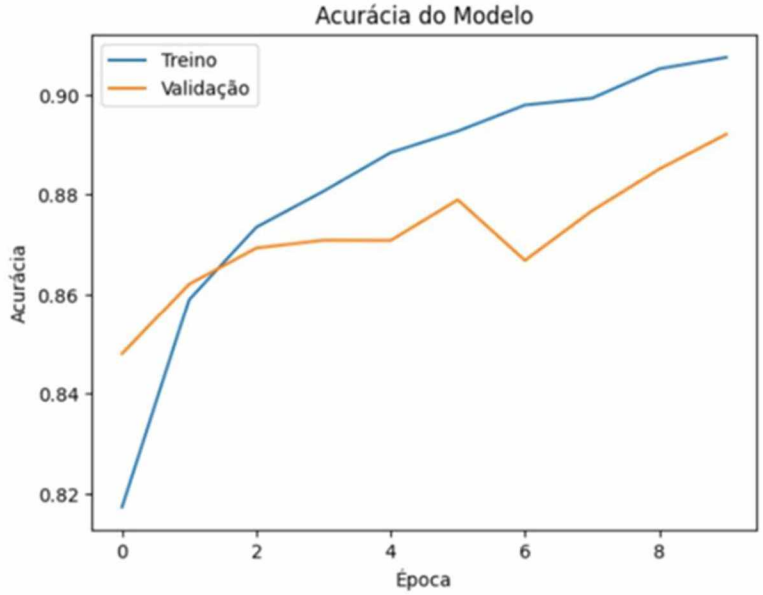

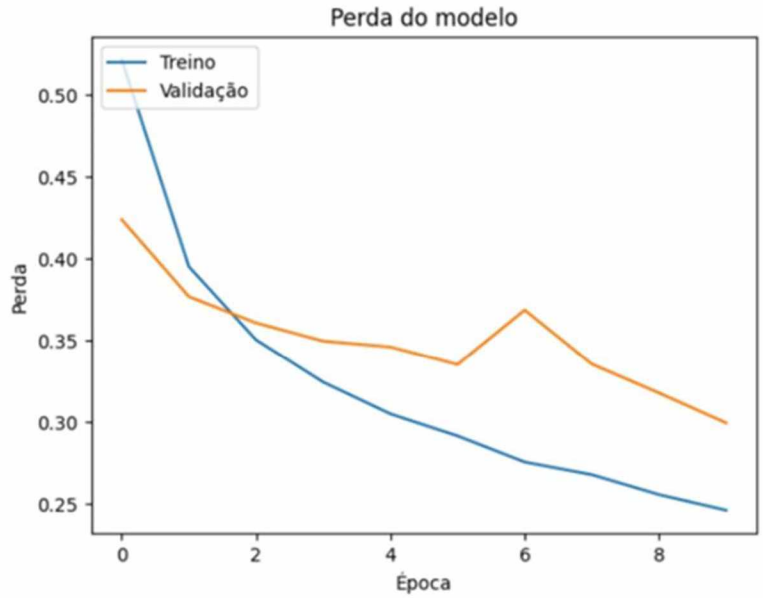


```
#Exemplo de predição do modelo
y_pred = model.predict(x_test).argmax(axis=1)
print(y_pred)
```

```
657/657 ━━━━━━━━━━━━━━━━━━━━ 1s 2ms/step
[2 7 0 ... 4 7 7]
```

```
#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'>)
```

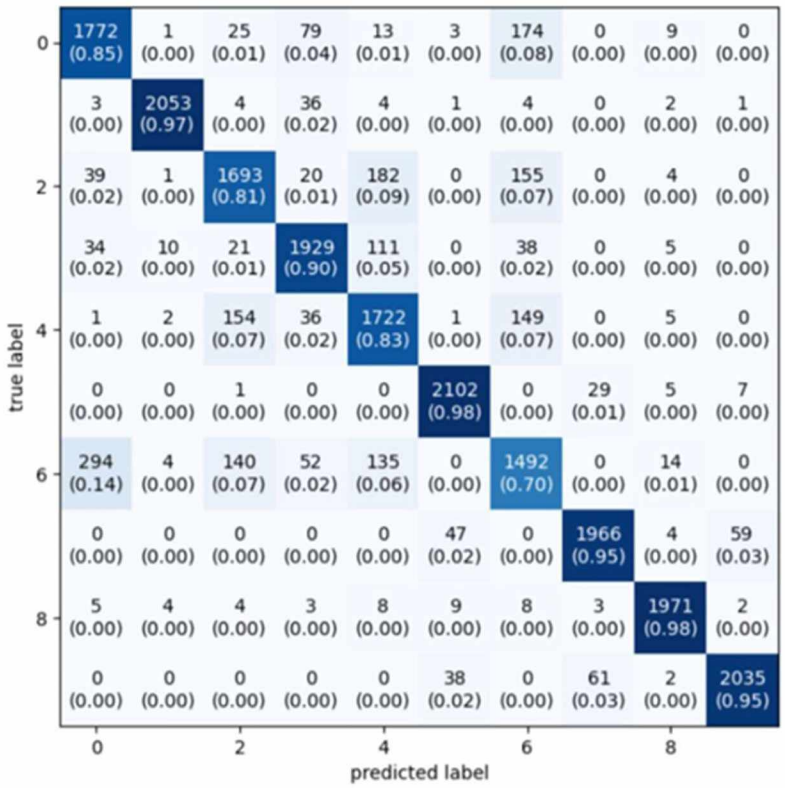


```
# Demonstrando uma predição errada
misclassified = np.where(y_pred != y_test)[0]
i = np.random.choice(misclassified)
```

```
plt.imshow(x_test[i].reshape(28, 28), cmap="gray")
plt.title("Rótulo verdadeiro: %s Rótulo predito: %s" % (y_test[i], y_pred[i]))
```

```
Text(0.5, 1.0, 'Rótulo verdadeiro: 6 Rótulo predito: 0')
```

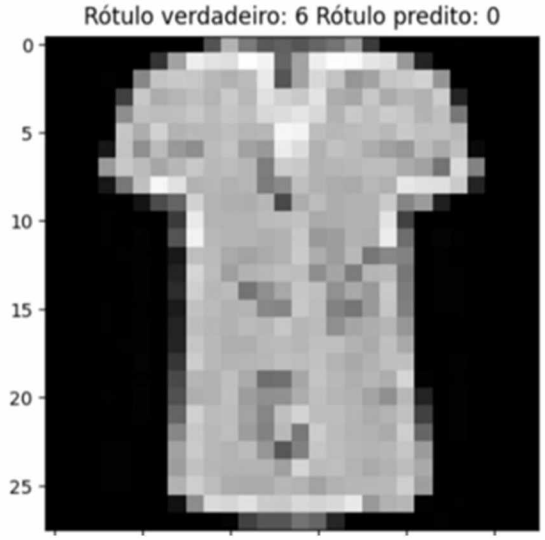

Rótulos da biblioteca (para referência):

https://github.com/zalandoresearch/fashion-mnist

Código	Rótulo
0	Camiseta/top
1	Calça
2	Suéteres
3	Vestido
4	Casacos
5	Sandálias
6	Camisa
7	Tênis
8	Bolsa
9	Suéteres
2	Bota de tornozelo

2) RNA Regressão (Wine)

```
# Bibliotecas
import tensorflow as tf
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt

from tensorflow.python.keras import backend
from sklearn.model_selection import train_test_split
from sklearn.metrics import r2_score, mean_squared_error
from math import sqrt
```

```
#Importação dos dados
url = "https://archive.ics.uci.edu/ml/machine-learning-databases/wine-quality/winequality-red.csv"
data = pd.read_csv(url, delimiter=';')
```

```
#Traduzindo colunas para entender melhor os dados
df = pd.DataFrame(data)

df.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
]

print(df)
```

```
   acidez_fixa  acidez_volatil  acido_citrico  acucar_residual  cloretos  \
0          7.4           0.700           0.00              1.9     0.076
1          7.8           0.880           0.00              2.6     0.098
2          7.8           0.760           0.04              2.3     0.092
3         11.2           0.280           0.56              1.9     0.075
4          7.4           0.700           0.00              1.9     0.076
```

```
...          ...            ...           ...             ...       ...
1594         6.2           0.600         0.08             2.0     0.090
1595         5.9           0.550         0.10             2.2     0.062
1596         6.3           0.510         0.13             2.3     0.076
1597         5.9           0.645         0.12             2.0     0.075
1598         6.0           0.310         0.47             3.6     0.067

      dioxido_de_enxofre_livre  dioxido_de_enxofre_total  densidade    pH  \
0                         11.0                      34.0    0.99780  3.51
1                         25.0                      67.0    0.99680  3.20
2                         15.0                      54.0    0.99700  3.26
3                         17.0                      60.0    0.99800  3.16
4                         11.0                      34.0    0.99780  3.51
...                        ...                       ...        ...   ...
1594                      32.0                      44.0    0.99490  3.45
1595                      39.0                      51.0    0.99512  3.52
1596                      29.0                      40.0    0.99574  3.42
1597                      32.0                      44.0    0.99547  3.57
1598                      18.0                      42.0    0.99549  3.39

      sulfatos  alcool  score_qualidade_vinho
0         0.56     9.4                      5
1         0.68     9.8                      5
2         0.65     9.8                      5
3         0.58     9.8                      6
4         0.56     9.4                      5
...        ...     ...                    ...
1594      0.58    10.5                      5
1595      0.76    11.2                      6
1596      0.75    11.0                      6
1597      0.71    10.2                      5
1598      0.66    11.0                      6

[1599 rows x 12 columns]
```

```
# Separação dos dados, removendo primeira coluna
X = df.iloc[1:, :-1].values.astype(float)
Y = df.iloc[1:, -1].values.astype(float)

print(X)
```

```
[[ 7.8    0.88   0.    ...  3.2    0.68   9.8  ]
 [ 7.8    0.76   0.04  ...  3.26   0.65   9.8  ]
 [11.2    0.28   0.56  ...  3.16   0.58   9.8  ]
 ...
 [ 6.3    0.51   0.13  ...  3.42   0.75  11.   ]
 [ 5.9    0.645  0.12  ...  3.57   0.71  10.2  ]
 [ 6.     0.31   0.47  ...  3.39   0.66  11.   ]]
```

```
# Separação para treinamento e teste do modelo
x_train, x_test, y_train, y_test = train_test_split(X, Y, test_size=0.25)
```

```
# Definição do 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)
```

```
# Funções de avaliação da regressão

def rmse(y_true, y_pred):
  return backend.sqrt(backend.mean(backend.square(y_pred - y_true), axis=-1))
```

```python
def r2(y_true, y_pred):
  media = backend.mean(y_true)
  num   = backend.sum(backend.square(y_true - y_pred))
  den   = backend.sum(backend.square(y_true - media))
  return (1.0 - num/den)
```

```python
#Definição do modelo

optimizer=tf.keras.optimizers.Adam(learning_rate=0.05)
# optimizer=tf.keras.optimizers.SGD(learning_rate=0.2, momentum=0.5)
# optimizer=tf.keras.optimizers.RMSprop(0.01)

model.compile(optimizer=optimizer,
              loss="mse",
              metrics=[rmse, r2])
```

```python
# Callback para parar treinamento
early_stop = tf.keras.callbacks.EarlyStopping(
                            monitor='val_loss',
                            patience=20,
                            restore_best_weights=True)
```

```python
# Épocas de treinamento com callback
history = model.fit(x_train, y_train,
              epochs=1500,
              validation_data=(x_test, y_test),
              callbacks=[early_stop])
```

```
38/38 ━━━━━━━━━━━━━━━━━━━━ 0s 2ms/step - loss: 0.5030 - r2: -42.6395 - rmse: 0.9095 - val_loss: 0.4362 - val_r2: -36.6058 - val_rmse: 0.8346
Epoch 12/1500
38/38 ━━━━━━━━━━━━━━━━━━━━ 0s 2ms/step - loss: 0.5046 - r2: -41.6447 - rmse: 0.9125 - val_loss: 0.5794 - val_r2: -43.7684 - val_rmse: 0.9008
Epoch 13/1500
38/38 ━━━━━━━━━━━━━━━━━━━━ 0s 8ms/step - loss: 0.5218 - r2: -43.4222 - rmse: 0.9134 - val_loss: 0.4211 - val_r2: -39.9609 - val_rmse: 0.8667
Epoch 14/1500
38/38 ━━━━━━━━━━━━━━━━━━━━ 0s 2ms/step - loss: 0.4874 - r2: -42.4220 - rmse: 0.9115 - val_loss: 0.4585 - val_r2: -45.2604 - val_rmse: 0.9086
Epoch 15/1500
38/38 ━━━━━━━━━━━━━━━━━━━━ 0s 2ms/step - loss: 0.5451 - r2: -45.3555 - rmse: 0.9532 - val_loss: 0.4151 - val_r2: -40.9818 - val_rmse: 0.8759
Epoch 16/1500
38/38 ━━━━━━━━━━━━━━━━━━━━ 0s 2ms/step - loss: 0.4804 - r2: -42.5756 - rmse: 0.9343 - val_loss: 0.4336 - val_r2: -43.1451 - val_rmse: 0.8942
Epoch 17/1500
38/38 ━━━━━━━━━━━━━━━━━━━━ 0s 2ms/step - loss: 0.4665 - r2: -44.9799 - rmse: 0.9198 - val_loss: 0.5208 - val_r2: -50.4987 - val_rmse: 0.9480
Epoch 18/1500
38/38 ━━━━━━━━━━━━━━━━━━━━ 0s 2ms/step - loss: 0.5117 - r2: -45.9018 - rmse: 0.9733 - val_loss: 0.4162 - val_r2: -40.8887 - val_rmse: 0.8744
Epoch 19/1500
38/38 ━━━━━━━━━━━━━━━━━━━━ 0s 2ms/step - loss: 0.5156 - r2: -45.8186 - rmse: 0.9728 - val_loss: 0.4263 - val_r2: -41.6414 - val_rmse: 0.8767
Epoch 20/1500
38/38 ━━━━━━━━━━━━━━━━━━━━ 0s 2ms/step - loss: 0.4739 - r2: -46.0221 - rmse: 0.9295 - val_loss: 0.5355 - val_r2: -53.1375 - val_rmse: 0.9659
Epoch 21/1500
38/38 ━━━━━━━━━━━━━━━━━━━━ 0s 2ms/step - loss: 0.5659 - r2: -52.7100 - rmse: 0.9786 - val_loss: 0.4740 - val_r2: -41.4287 - val_rmse: 0.8768
Epoch 22/1500
38/38 ━━━━━━━━━━━━━━━━━━━━ 0s 2ms/step - loss: 0.4531 - r2: -47.2599 - rmse: 0.9269 - val_loss: 0.4451 - val_r2: -40.9830 - val_rmse: 0.8735
Epoch 23/1500
38/38 ━━━━━━━━━━━━━━━━━━━━ 0s 2ms/step - loss: 0.4500 - r2: -44.7042 - rmse: 0.9208 - val_loss: 0.5199 - val_r2: -42.8665 - val_rmse: 0.8886
Epoch 24/1500
38/38 ━━━━━━━━━━━━━━━━━━━━ 0s 10ms/step - loss: 0.4342 - r2: -45.4082 - rmse: 0.9143 - val_loss: 0.4403 - val_r2: -40.0274 - val_rmse: 0.8653
Epoch 25/1500
38/38 ━━━━━━━━━━━━━━━━━━━━ 0s 3ms/step - loss: 0.4382 - r2: -43.8237 - rmse: 0.9117 - val_loss: 0.4461 - val_r2: -40.9070 - val_rmse: 0.8726
Epoch 26/1500
38/38 ━━━━━━━━━━━━━━━━━━━━ 0s 3ms/step - loss: 0.4996 - r2: -48.9225 - rmse: 0.9567 - val_loss: 0.4725 - val_r2: -41.4147 - val_rmse: 0.8779
Epoch 27/1500
38/38 ━━━━━━━━━━━━━━━━━━━━ 0s 3ms/step - loss: 0.4841 - r2: -46.1856 - rmse: 0.9288 - val_loss: 0.4082 - val_r2: -40.3861 - val_rmse: 0.8701
Epoch 28/1500
38/38 ━━━━━━━━━━━━━━━━━━━━ 0s 3ms/step - loss: 0.4310 - r2: -44.3685 - rmse: 0.9366 - val_loss: 0.4053 - val_r2: -40.6265 - val_rmse: 0.8729
Epoch 29/1500
38/38 ━━━━━━━━━━━━━━━━━━━━ 1s 20ms/step - loss: 0.4824 - r2: -44.8805 - rmse: 0.9729 - val_loss: 0.5177 - val_r2: -52.9040 - val_rmse: 0.9655
Epoch 30/1500
38/38 ━━━━━━━━━━━━━━━━━━━━ 1s 8ms/step - loss: 0.4717 - r2: -46.5733 - rmse: 0.9433 - val_loss: 0.4309 - val_r2: -43.5774 - val_rmse: 0.8991
```

```
Epoch 30/1500
38/38 ━━━━━━━━━━━━━━━━━━━━ 1s 8ms/step - loss: 0.4717 - r2: -46.5733 - rmse: 0.9433 - val_loss: 0.4309 - val_r2: -43.5774 - val_rmse: 0.8991
Epoch 31/1500
38/38 ━━━━━━━━━━━━━━━━━━━━ 1s 13ms/step - loss: 0.4588 - r2: -45.1689 - rmse: 0.9391 - val_loss: 0.5079 - val_r2: -43.0725 - val_rmse: 0.8866
Epoch 32/1500
38/38 ━━━━━━━━━━━━━━━━━━━━ 0s 2ms/step - loss: 0.5069 - r2: -48.3418 - rmse: 0.9588 - val_loss: 0.4325 - val_r2: -46.6504 - val_rmse: 0.9241
Epoch 33/1500
38/38 ━━━━━━━━━━━━━━━━━━━━ 0s 2ms/step - loss: 0.4986 - r2: -47.6906 - rmse: 0.9801 - val_loss: 0.4459 - val_r2: -47.3790 - val_rmse: 0.9266
Epoch 34/1500
38/38 ━━━━━━━━━━━━━━━━━━━━ 0s 2ms/step - loss: 0.4830 - r2: -45.8413 - rmse: 0.9580 - val_loss: 0.4152 - val_r2: -42.5633 - val_rmse: 0.8900
Epoch 35/1500
38/38 ━━━━━━━━━━━━━━━━━━━━ 0s 2ms/step - loss: 0.4729 - r2: -46.5953 - rmse: 0.9457 - val_loss: 0.5040 - val_r2: -43.5390 - val_rmse: 0.8941
Epoch 36/1500
38/38 ━━━━━━━━━━━━━━━━━━━━ 0s 2ms/step - loss: 0.4702 - r2: -44.2827 - rmse: 0.9567 - val_loss: 0.4051 - val_r2: -43.2745 - val_rmse: 0.8962
Epoch 37/1500
38/38 ━━━━━━━━━━━━━━━━━━━━ 0s 2ms/step - loss: 0.5189 - r2: -47.5978 - rmse: 0.9582 - val_loss: 0.7064 - val_r2: -53.4220 - val_rmse: 0.9744
Epoch 38/1500
38/38 ━━━━━━━━━━━━━━━━━━━━ 0s 2ms/step - loss: 0.5983 - r2: -49.7420 - rmse: 1.0118 - val_loss: 0.4039 - val_r2: -40.9433 - val_rmse: 0.8746
Epoch 39/1500
38/38 ━━━━━━━━━━━━━━━━━━━━ 1s 26ms/step - loss: 0.4892 - r2: -44.8016 - rmse: 0.9742 - val_loss: 0.4633 - val_r2: -40.3839 - val_rmse: 0.8646
Epoch 40/1500
```

```
# Resultados do treinamento e teste
print("Resultado treinamento: ", model.evaluate(x_train, y_train))
print("Resultado teste: ", model.evaluate(x_test, y_test))
```

```
38/38 ━━━━━━━━━━━━━━━━━━━━ 1s 15ms/step - loss: 0.4643 - r2: -42.2929 - rmse: 0.9339
Resultado treinamento:  [0.42607665061950684, 0.9177801609039307, -41.79179382324219]
13/13 ━━━━━━━━━━━━━━━━━━━━ 0s 16ms/step - loss: 0.3757 - r2: -42.1896 - rmse: 0.8604
Resultado teste:  [0.3936346471309662, 0.8682646155357361, -40.01666259765625]
```

```
# Gráficos durante o treinamento e teste

plt.plot(history.history['rmse'])
plt.plot(history.history['val_rmse'])
plt.title('Erro quadrático médio do modelo')
plt.ylabel('RMSE')
plt.xlabel('Época')
plt.legend(['Treino', 'Validação'], loc='upper right')
plt.show()


plt.plot(history.history['loss'])
plt.plot(history.history['val_loss'])
plt.title('Perda do modelo')
plt.ylabel('Perda')
plt.xlabel('Época')
plt.legend(['Treino', 'Validação'], loc='upper right')
plt.show()


plt.plot(history.history['r2'])
plt.plot(history.history['val_r2'])
plt.title('Coeficiente de determinação do modelo')
plt.ylabel('Coeficiente')
plt.xlabel('Época')
plt.legend(['Treino', 'Validação'], loc='lower right')
plt.show()
```

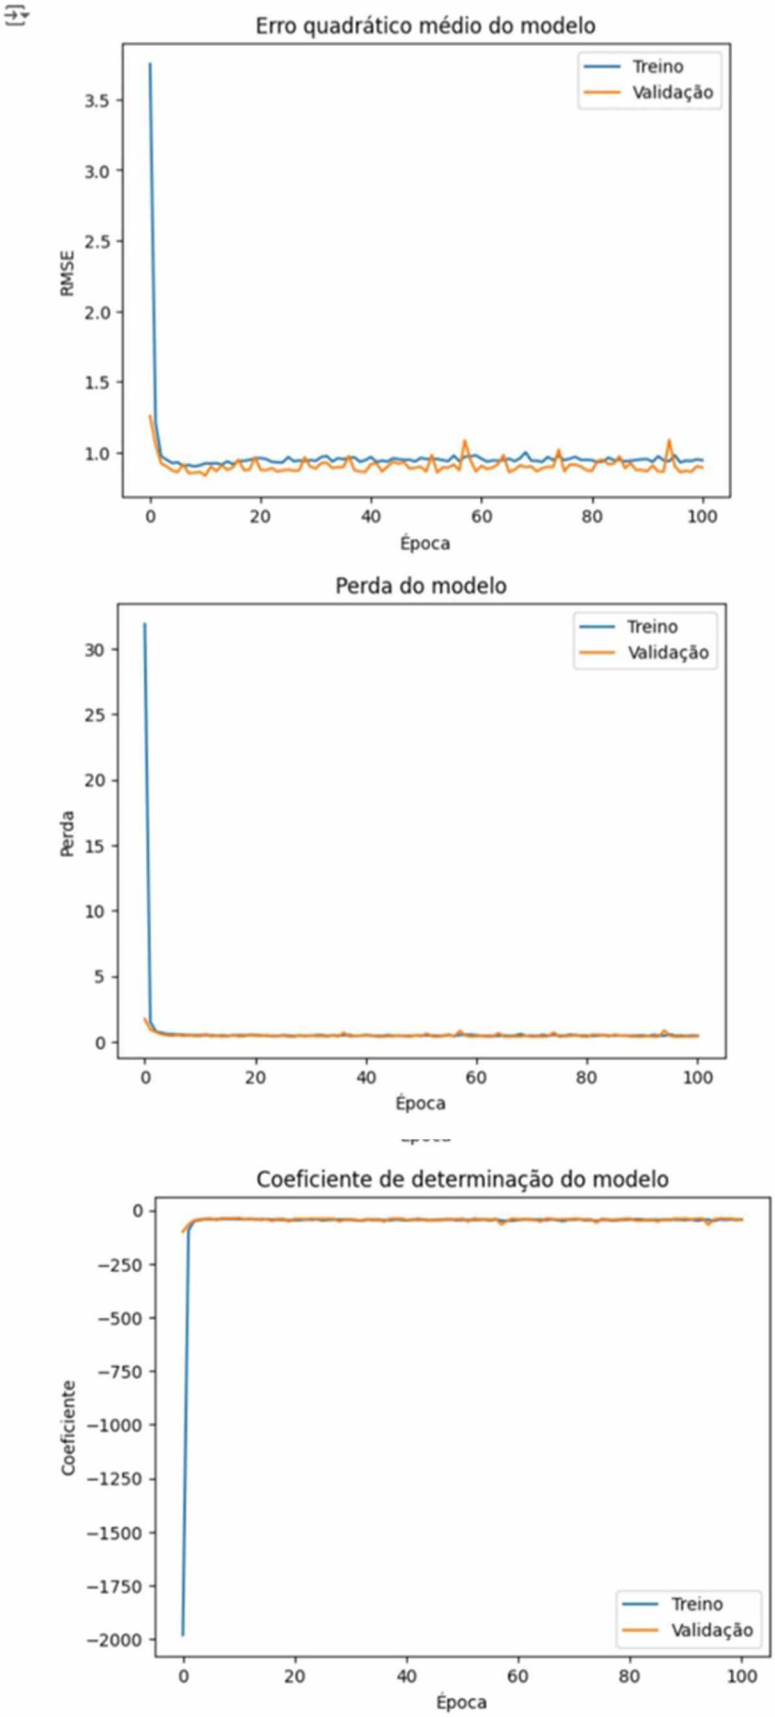
Erro quadrático médio do modelo
Treino
Validação
RMSE
Época
Perda do modelo
Perda
Coeficiente de determinação do modelo
Coeficiente

```python
# Predição com o modelo

y_pred = model.predict(x_test).flatten()
print(y_pred)
```

```
[4.8672523 5.977433  5.298209  5.883625  5.7786818 5.991962  5.340973
 6.1581817 5.6632643 5.701598  6.037753  6.592324  5.328522  5.088885
 5.543335  6.060793  6.2033653 5.910296  5.0974007 4.8263865 6.5213995
 5.7125206 5.5288973 5.6978626 5.654664  5.797232  5.001116  5.2429886
 5.8926153 5.7402964 5.1138244 5.9868255 5.8160458 6.5218925 5.1692305
 5.2375326 5.643093  5.9601054 6.4342165 5.8852177 5.191886  5.660449
 5.473385  5.9333515 5.0538883 5.9096622 5.847824  5.245156  6.3149676
 5.2928    5.423332  5.654597  6.343215  5.261221  4.9001484 6.203624
 5.865238  6.317827  5.222643  5.40904   5.9434376 5.060213  5.5843487
 5.6030917 5.170514  5.4933786 5.333521  5.8941746 5.440053  6.153892
 5.731764  5.196306  6.1162415 5.481457  5.4430976 5.4335194 5.830949
 5.413283  5.753912  6.200671  5.595646  5.1229544 5.767761  5.2502975
 5.648843  5.223076  5.984506  4.9218884 5.1493707 5.8118324 5.543631
 6.409523  5.0480733 5.2112985 5.34209   5.149371  5.876257  6.0162506
 5.367725  5.5663157 5.7703567 5.1698637 5.30606   5.296498  5.295879
 5.3604403 6.317827  5.0549192 5.2457175 5.0301123 5.968399  6.2390585
 5.855746  4.936945  5.6481886 5.3887854 5.5196886 4.9775815 5.6676555
 5.3519154 5.7045937 5.454116  5.2688456 6.3520193 4.998802  6.3672237
 5.0026817 6.2659483 5.7076006 5.046815  5.583876  6.4524803 5.556161
 6.233242  6.0616426 5.2689157 5.5693808 4.944804  5.3336825 5.96939
 5.452164  5.754266  5.8691015 5.0118914 6.1105065 6.0929976 6.175446
 5.075632  5.0685153 5.1603785 5.4498243 5.3957634 5.3466015 5.814055
 6.4380355 6.281309  5.883625  5.3541822 5.7204933 6.0582166 5.340782
 5.3296924 4.947322  6.0659356 5.730406  5.3336825 5.22814   5.3279305
 5.533479  5.3085775 5.580185  5.3591986 5.792576  5.36333   4.7873297
 4.95238   6.207378  5.155093  6.254943  6.201291  6.316066  5.0457497
 4.864609  5.337472  5.5929966 6.201198  5.0517683 5.4790206 5.493619
 5.048253  5.343215  6.1178217 5.814055  5.9873915 5.3007703 6.0271287
 5.4833956 5.0045357 4.5467687 5.0127096 6.190041  5.445063  5.512149
 5.8328466 6.346902  5.6817575 5.3390765 5.9023194 5.4635344 6.0668955
 5.943298  4.8528056 5.784584  6.0461316 5.3068495 6.453708  5.1070232
 5.723259  5.614018  5.670738  6.150578  5.8983192 5.31737   5.5162416
 5.3380485 5.333521  5.1571136 5.3541822 5.485459  6.0704794 4.9264107
 6.3636117 5.8004894 5.951803  5.1119504 5.648406  5.0942917 5.640893
 5.5299044 5.701598  5.3185205 5.244891  5.1690855 6.0582166 5.9499345
 5.07246   6.35772   5.617006  5.0615225 5.6442018 6.233242  5.7233057
 5.4488173 5.2284894 6.0005994 5.798398  5.5205193 4.8556585 6.1015077
 6.15855   5.617347  5.4541197 5.315198  5.420233  5.090685  5.194495
 5.8603225 5.9437723 5.38017   5.566826  6.072126  5.1666613 6.124735
 6.0715165 4.932083  6.3842263 5.1977224 4.971037  5.373157  6.0237617
 6.017794  5.658801  5.994917  5.8749847 5.016589  5.4938116 6.193963
 5.0301123 5.7984776 4.919219  5.2490177 5.07262   4.847314  4.791117
 5.2573223 6.05501   5.261333  5.527498  6.16512   4.920385  5.935751
 5.3737955 6.1614747 5.6987104 5.953808  5.1309214 6.1461368 5.506214
 4.9722576 4.938671  5.2931404 5.5626698 5.1540985 5.096057  5.1900177
 5.4302206 5.5929966 5.772382  4.9823294 5.763646  5.432001  5.461852
 5.0849237 6.113697  4.8648567 6.0817227 6.0206275 5.4188623 5.2881875
 5.0003247 6.1525307 5.1955338 6.110401  5.4713354 5.3796597 5.4797373
 5.474763  5.8983755 5.333611  5.378911  5.400511  5.515419  5.2590427
 5.343156  5.9645696 6.2085557 5.350751  5.1430297 5.5651608 5.1571836
 6.0953245 5.833683  5.192988  5.5082564 5.694469  5.7404046 6.142609
 6.2553716 5.747788  5.0373564 5.504937  4.9667745 5.027594  5.2595205
 4.931018  5.3307133 5.633752  5.135465  6.022397  4.9148765 5.4558115
 5.5287046 5.0111904 5.684088  5.6066785 5.6676555 5.7558026 5.3420734
 5.264943  5.593643  5.6259933 5.9581947 5.2596064 6.2995005 5.7849035
 5.2590427 6.307364  5.833934  5.5520678 5.0480237 5.477087  5.2683115
 6.1745977 5.8075333 5.153427  5.6164255 6.5782733 6.002743  6.1680903
 5.1307864]
```

```
# Avaliando modelo treinado
mse  = mean_squared_error(y_test, y_pred)
rmse = sqrt(mse)
r2   = r2_score(y_test, y_pred)

print("mse     = ", mse)
print("rmse    = ", rmse)
print("r2      = ", r2)
```

```
mse     =  0.3936346721908853
rmse    =  0.6274031177726848
r2      =  0.3422361379981237
```

Explicação:

O modelo de previsão da qualidade do vinho obteve os seguintes resultados:

1. MSE de 0.3936: Isso significa que, em média, a diferença entre as previsões do modelo e os valores reais de qualidade, quando elevada ao quadrado, é de 0.4038. Quanto menor esse valor, melhor, então 0.4038 é um erro razoável, mas há espaço para melhorias.
2. RMSE de 0.6274: Este é o erro médio do modelo, mas em unidades diretas de qualidade do vinho. Ou seja, em média, o modelo erra por cerca de 0.64 unidades na escala de qualidade. Novamente, não é um erro gigantesco, mas também não é extremamente preciso.
3. R^2 de 0.3422: Isso quer dizer que o modelo consegue explicar cerca de 40% da variação na qualidade do vinho. Ou seja, ele tem uma boa capacidade explicativa, mas ainda há uma grande parte da variação que não é explicada pelas características do vinho usadas no modelo.

Em resumo, o modelo está razoavelmente bom, mas há margem para melhorar. Ele consegue capturar uma parte significativa da variação da qualidade do vinho, mas não de forma perfeita, e ainda com um erro médio considerável.

3) Sistema de Recomendação (Books)

```
#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
```

```
# Importação da base.csv (via ação do usuario)
from google.colab import files
import io
uploaded = files.upload()
```

```
#Carregando base importada (usamos o on bad lines para evitar falhas)
import io
filename = next(iter(uploaded))
df = pd.read_csv(filename,delimiter=",", on_bad_lines="skip")
df
```

	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
...	...	...	...	...	...	...	...
108966	743436865	Funny Money	James Swain	2002	Atria	29888	10
108967	451410394	Sun Valley	Gena Hale	2002	Signet Book	29888	10
108968	345391101	The Adventures of Lando Calrissian: Lando Calr...	L. Neil Smith	1994	Del Rey Books	29888	6
108969	1591050480	Beloved Stranger	Patricia Crossley	2002	Novelbooks	29888	9
108970	051732170X	Who's Who in the Bible	RONALD BROWNRIGG	1993	Testament	29888	4

108971 rows × 7 columns

```
#Embeddings (ISBN e ID_usuário precisam ser categóricas)

df.ISBN = pd.Categorical(df.ISBN)
df['ISBN'] = df.ISBN.cat.codes

df.ID_usuario = pd.Categorical(df.ID_usuario)
df['ID_usuario'] = df.ID_usuario.cat.codes



# Dimensões
N = len(set(df.ISBN))
M = len(set(df.ID_usuario))

# dimensão do embedding (tentar outros)
K = 10
```

```
# Livro
u = Input(shape=(1,))
u_emb = Embedding(N, K)(u) # saída : num_samples, 1, K
u_emb = Flatten()(u_emb)   # saída : num_samples, K

# Usuário
m = Input(shape=(1,))
m_emb = Embedding(M, K)(m)  # saída : num_samples, 1, K
m_emb = Flatten()(m_emb)    # saída : num_samples, K

x = Concatenate()([u_emb, m_emb])

x = Dense(1024, activation="relu")(x)
x = Dense(1)(x)

model = Model(inputs=[u, m], outputs=x)
```

```
# Criação do modelo
model.compile(
    loss="mse",
    optimizer=SGD(learning_rate=0.08, momentum=0.9)
)
```

```
# Separando os dados para treino e teste (considerando apenas 3 itens da tabela)

ISBN, ID_usuario, Notas = shuffle(df.ISBN, df.ID_usuario, df.Notas)

Ntrain = int(0.8 * len(Notas)) # separar os dados 80% x 20%

train_ISBN = ISBN[:Ntrain]
train_ID_usuario = ID_usuario[:Ntrain]
train_Notas = Notas[:Ntrain]

test_ISBN = ISBN[Ntrain:]
test_ID_usuario = ID_usuario[Ntrain:]
test_Notas = Notas[Ntrain:]

avg_Notas = train_Notas.mean()
train_Notas = train_Notas - avg_Notas
test_Notas = test_Notas - avg_Notas
```

```python
# Treinamento do modelo em épocas
epochs = 25

history = model.fit(
    x=[train_ISBN, train_ID_usuario],
    y=train_Notas,
    epochs=epochs,
    batch_size=1024,
    verbose=2, # não imprime o progresso
    validation_data=([test_ISBN, test_ID_usuario], test_Notas)
)
```

```
Epoch 1/25
86/86 - 2s - 21ms/step - loss: 9.9849 - val_loss: 9.9525
Epoch 2/25
86/86 - 2s - 29ms/step - loss: 9.9861 - val_loss: 9.9799
Epoch 3/25
86/86 - 0s - 2ms/step - loss: 9.9822 - val_loss: 9.9550
Epoch 4/25
86/86 - 0s - 3ms/step - loss: 9.9842 - val_loss: 9.9620
Epoch 5/25
86/86 - 0s - 4ms/step - loss: 9.9144 - val_loss: 10.0839
Epoch 6/25
86/86 - 0s - 4ms/step - loss: 9.3058 - val_loss: 18.7664
Epoch 7/25
86/86 - 1s - 11ms/step - loss: 3.9738 - val_loss: 11.4292
Epoch 8/25
86/86 - 1s - 13ms/step - loss: 1.2417 - val_loss: 10.7514
Epoch 9/25
86/86 - 1s - 6ms/step - loss: 0.3277 - val_loss: 10.5730
Epoch 10/25
86/86 - 0s - 4ms/step - loss: 0.1753 - val_loss: 10.5511
Epoch 11/25
86/86 - 0s - 3ms/step - loss: 0.1349 - val_loss: 10.5340
Epoch 12/25
86/86 - 0s - 2ms/step - loss: 0.1148 - val_loss: 10.5525
Epoch 13/25
86/86 - 0s - 2ms/step - loss: 0.1076 - val_loss: 10.5347
Epoch 14/25
86/86 - 0s - 2ms/step - loss: 0.1027 - val_loss: 10.5434
Epoch 15/25
86/86 - 0s - 3ms/step - loss: 0.0975 - val_loss: 10.5739
Epoch 16/25
86/86 - 0s - 3ms/step - loss: 0.0942 - val_loss: 10.5269
Epoch 17/25
86/86 - 0s - 3ms/step - loss: 0.0895 - val_loss: 10.5678
Epoch 18/25
86/86 - 0s - 3ms/step - loss: 0.0797 - val_loss: 10.5565
Epoch 19/25
86/86 - 0s - 2ms/step - loss: 0.0660 - val_loss: 10.5521
Epoch 20/25
86/86 - 0s - 3ms/step - loss: 0.0532 - val_loss: 10.5563
Epoch 21/25
86/86 - 0s - 3ms/step - loss: 0.0402 - val_loss: 10.5592
Epoch 22/25
86/86 - 0s - 3ms/step - loss: 0.0296 - val_loss: 10.5569
Epoch 23/25
86/86 - 0s - 2ms/step - loss: 0.0210 - val_loss: 10.5609
Epoch 24/25
86/86 - 0s - 3ms/step - loss: 0.0147 - val_loss: 10.5610
Epoch 25/25
86/86 - 0s - 2ms/step - loss: 0.0100 - val_loss: 10.5587
```

```
# Gráfico de perda
plt.plot(history.history["loss"], label="loss")
plt.plot(history.history["val_loss"], label="val_loss")
plt.legend()
plt.show()
```

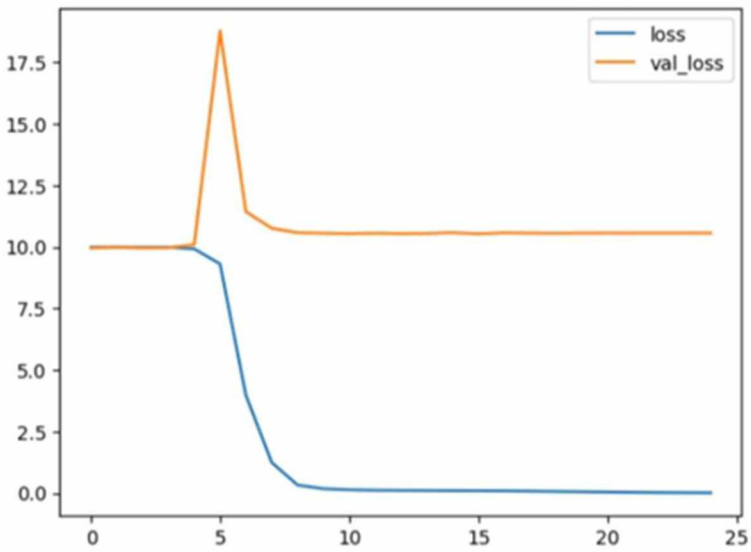


```
# Gerar o array com o usuário único
# repete a quantidade de livros
input_usuario = np.repeat(a=29888, repeats=N)
books = np.array(list(set(ISBN)))

preds = model.predict( [input_usuario, books] )

# descentraliza as predições
rat = preds.flatten() + avg_Notas

# índice da maior nota
idx = np.argmax(rat)

print("Recomendação: Livro - ", books[idx], " / ", rat[idx] , "*")
```

```
3406/3406 ━━━━━━━━━━━━━━━━━━━━ 12s 4ms/step
Recomendação: Livro -  2412  /  1.1802464 *
```

```
# Identificação do título sugerido para usuário
print( df[df['ISBN'] == books[idx]].values[0])
```

```
[2412 'The Perfect Storm: A True Story of Men Against the Sea'
 'Sebastian Junger' 1997 'Little Brown and Company' 10202 10]
```

4) Deepdream

```
#Bibliotecas

import tensorflow as tf
import numpy as np
import matplotlib as mpl
import IPython.display as display
import PIL.Image
```

```
# Imagem de referência
url = "https://commons.wikimedia.org/wiki/Special:FilePath/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)

# Mostra a imagem
def show(img):
  display.display(PIL.Image.fromarray(np.array(img)))


# Redução do tamanho da imagem para facilitar o trabalho da RNN
original_img = download(url, max_dim=500)
show(original_img)
display.display(display.HTML('Image cc-by: <a "href=https://commons.wikimedia.org/wiki/File:Felis_catus-cat_on_snow.jpg">Von.grzanka</a>'))
```

```
Downloading data from https://commons.wikimedia.org/wiki/Special:FilePath/Felis_catus-cat_on_snow.jpg
2125399/2125399 ━━━━━━━━━━━━━━━━━━━━ 1s 1us/step
```

Image cc-by: Von.grzanka

```python
#Modelo de base já treinado
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 ━━━━━━━━━━━━━━━━━━━━ 8s 0us/step
```

```python
# Maximizando as ativações das camadas
names = ['mixed3', 'mixed5']
layers = [base_model.get_layer(name).output for name in names]

# Criação do modelo
dream_model = tf.keras.Model(inputs=base_model.input, outputs=layers)
```

```python
def calc_loss(img, model):
  # Passe a imagem pelo modelo para recuperar as ativações.
  # Converte a imagem em um batch de tamanho 1.
  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)
```

```python
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:
          # Gradientes relativos a img
          tape.watch(img)
          loss = calc_loss(img, self.model)

        # Calculo do gradiente da perda em relação aos pixels da imagem de entrada.
        gradients = tape.gradient(loss, img)

        # Normalizacao dos gradintes
        gradients /= tf.math.reduce_std(gradients) + 1e-8

        # Na subida gradiente, a "perda" é maximizada.
        # Você pode atualizar a imagem adicionando diretamente os gradientes (porque eles têm o mesmo formato!)
        img = img + gradients*step_size
        img = tf.clip_by_value(img, -1, 1)

      return loss, img
```

```
deepdream = DeepDream(dream_model)
```

```
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
```

```
dream_img = run_deep_dream_simple(img=original_img,
                                  steps=100, step_size=0.01)
```

```
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
```

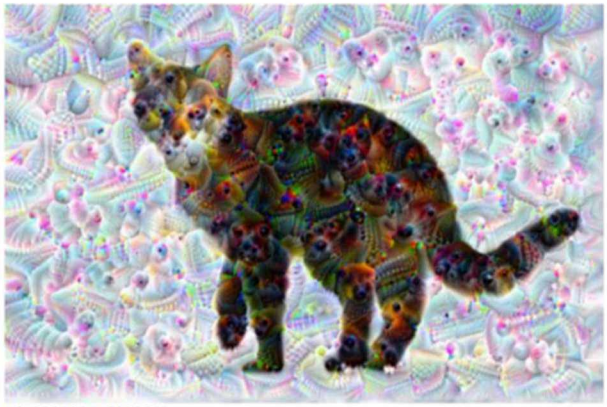

16.928105115890503

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

No trabalho abaixo utilizei a fonte de dados de pesquisa salarial de funcionários utilizada no curso de Python oferecido pelo CITS (Centro Internacional de Tecnologia em Software), instituto de P&DI o qual trabalho.

Subi a base na ferramenta analytics.zoho.com e ela gerou a visualização:

Com base nesta visualização e nos dados fiz o seguinte Storytelling (utilizei o chatgpt para formatar e ajustar o texto):

Contexto e Objetivo

A análise apresentada busca compreender a distribuição salarial dos funcionários de diferentes setores, níveis hierárquicos e formação acadêmica. Essa visualização de dados tem como público-alvo gestores de Recursos Humanos, tomadores de decisão e analistas financeiros, permitindo insights sobre disparidades salariais, tendências de crescimento e possíveis ajustes de remuneração para retenção de talentos.

Principais Descobertas

1. **Tendência de Crescimento Salarial**
   O total de faixas salariais aumentou de **231K em novembro para 348K em dezembro**, indicando um crescimento positivo. Esse aumento pode estar associado a ajustes salariais, promoções ou mudanças estruturais dentro das empresas.

2. **Distribuição Salarial**
   A maioria dos funcionários recebe entre **0-9K**, seguido pela faixa **9K-18K**.

Salários acima de **27K** são menos comuns, indicando que a maior parte da força de trabalho está concentrada em níveis iniciais e intermediários.

3. **Impacto da Escolaridade no Salário**
   Profissionais com **pós-graduação** atingem os maiores salários, com um total de **13.84M** em faixa salarial. Por outro lado, aqueles sem formação formal possuem uma remuneração significativamente menor (**322.00K**).
4. **Disparidade de Gênero**
   - O maior salário registrado para o gênero masculino é de **9.98M**, enquanto a média é **6.92M**.
   - A análise temporal mostra que os homens possuem maior representação nas faixas salariais mais altas.
   - **N**o nível Sênior, há uma presença masculina predominante, reforçando possíveis desigualdades.
5. **Distribuição por Nível Profissional**
   - Os funcionários no nível **Sênior** possuem os maiores salários.
   - Júniores e Plenos têm crescimento salarial consistente.
   - Gestores apresentam valores medianos em relação aos outros níveis, possivelmente devido à distribuição dos setores.

Ações Possíveis

- **Revisão de Políticas Salariais**: Avaliar se a distribuição está alinhada com as metas da organização e corrigir eventuais distorções.
- **Programas de Capacitação**: Investir na formação acadêmica dos colaboradores pode gerar impacto direto nos ganhos.
- **Equidade de Gênero**: Implementar ações para reduzir a disparidade salarial entre gêneros, incentivando promoções e oportunidades iguais.
- **Planejamento de Carreira**: Criar programas de progressão salarial baseados em desempenho e experiência.

Conclusão

Esta análise oferece uma visão clara das tendências salariais dentro da organização. Com base nesses dados, os gestores podem tomar decisões mais assertivas para otimizar a remuneração, promover igualdade e garantir maior satisfação e retenção dos talentos.

Melhoria na visualização

Baseado no que tivemos nas aulas fiz um gráfico onde mostra a distribuição das faixas salariais. Ele destaca quais faixas têm maior concentração de funcionários, permitindo uma análise mais clara da estrutura salarial, o KDE indica a tendência geral da distribuição, observamos um pico em torno das faixas de R$ 6.000 a R$ 12.000, indicando que a maioria dos funcionários se encontra nessa faixa salarial.

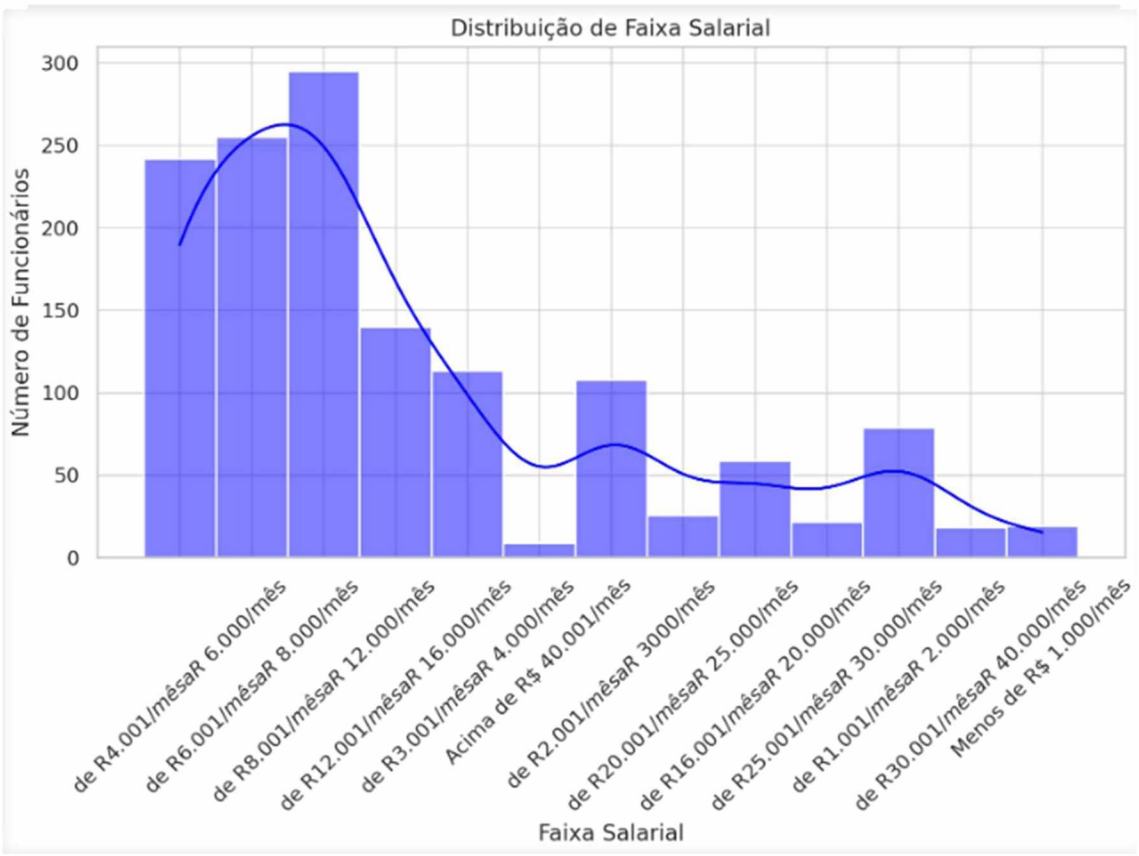

APÊNDICE 15 – TÓPICOS EM INTELIGÊNCIA ARTIFICIAL

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

```
## Biliotecas
import numpy as np
import matplotlib.pyplot as plt
import random
from itertools import permutations

## Parâmetros
# Parâmetros Iniciais
NUM_CIDADES = 100
POPULACAO_SIZE = 100
GERACOES = 1000
MUTACAO_RATE = 0.01
CROSSOVER_RATE = 0.90

cidades = np.random.rand(NUM_CIDADES, 2) * 100

## Funções de apoio

# Calcula a distância euclidiana (comprimento do vetor) total
percorrida no caminho
def calcular_distancia(caminho):
    return sum(np.linalg.norm(cidades[caminho[i]] -
cidades[caminho[i+1]]) for i in range(len(caminho)-1))


def criar_populacao():
    return [np.random.permutation(range(1, NUM_CIDADES)).tolist()
for _ in range(POPULACAO_SIZE)]

# Avalia a população com base na distância total do percurso
def avaliar_populacao(populacao):
    return sorted(populacao, key=lambda ind: calcular_distancia([0]
+ ind + [0]))

# Seleciona um indivíduo por torneio
def selecao_torneio(populacao):
    torneio = random.sample(populacao, 5)
    return min(torneio, key=lambda ind: calcular_distancia([0] + ind
+ [0]))
```

```
# Aplica crossover genético nos pais para gerar dois filhos
def crossover(pai1, pai2):
    tamanho = len(pai1)
    ponto1, ponto2 = sorted(random.sample(range(tamanho), 2))
    meio = pai1[ponto1:ponto2]
    filho1 = meio + [gene for gene in pai2 if gene not in meio]
    filho2 = meio + [gene for gene in pai1 if gene not in meio]
    return filho1, filho2

# Aplica mutação trocando duas cidades de posição
def mutacao(individuo):
    if random.random() < MUTACAO_RATE:
        i, j = random.sample(range(len(individuo)), 2)
individuo[i], individuo[j] = individuo[j], individuo[i]
    return individuo

# Imprime o percurso das cidades
def mostra_solucao(melhor_solucao, titulo):
    caminho = [0] + melhor_solucao + [0]
    plt.figure(figsize=(8, 8))
    plt.scatter(cidades[:, 0], cidades[:, 1], c='blue')
    plt.plot(cidades[caminho, 0], cidades[caminho, 1], 'r-', lw=1.5)
    plt.title(titulo)
    plt.show()

## Algoritmo e resultado

def main():

    populacao = criar_populacao()
    melhor_solucao = avaliar_populacao(populacao)[0]
    mostra_solucao(melhor_solucao, "Primeira melhor solução
(população inicial)")

    for _ in range(GERACOES):
        nova_populacao = []
        while len(nova_populacao) < POPULACAO_SIZE * CROSSOVER_RATE:
            pai1, pai2 = selecao_torneio(populacao),
selecao_torneio(populacao)
            filho1, filho2 = crossover(pai1, pai2)
            nova_populacao.extend([filho1, filho2])

        while len(nova_populacao) < POPULACAO_SIZE:

nova_populacao.append(mutacao(selecao_torneio(populacao)))

        populacao =
avaliar_populacao(nova_populacao)[:POPULACAO_SIZE]
        melhor_solucao = populacao[0]

    mostra_solucao(melhor_solucao, "Melhor solução após 1000
gerações")


main()
```

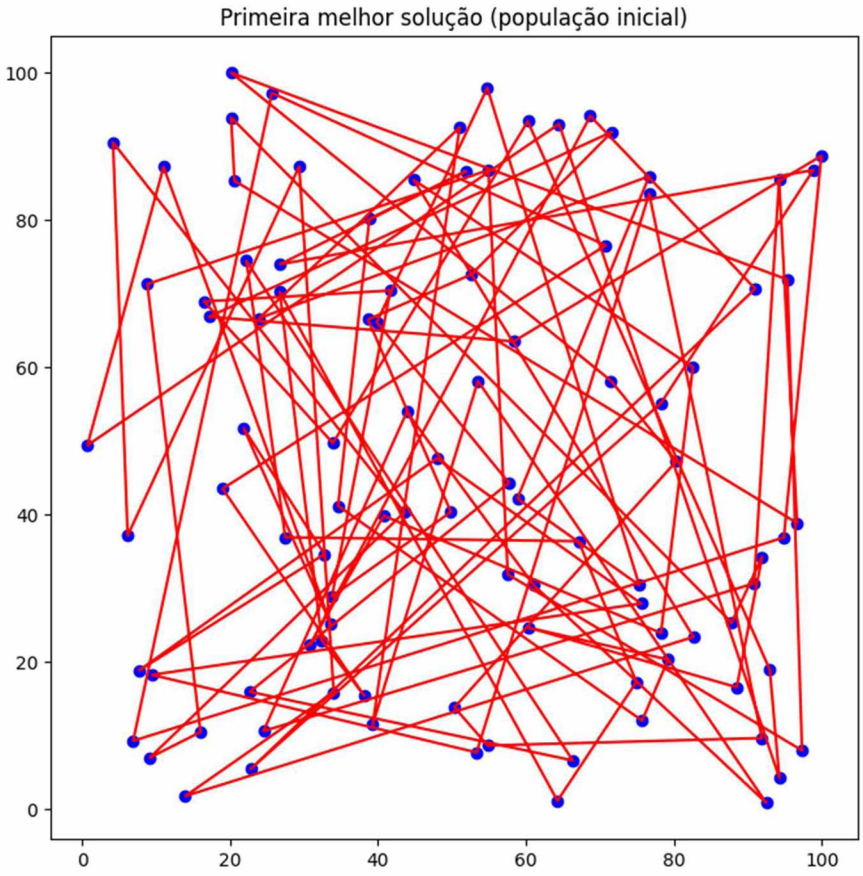
Primeira melhor solução (população inicial)
0
20
40
60
80
100

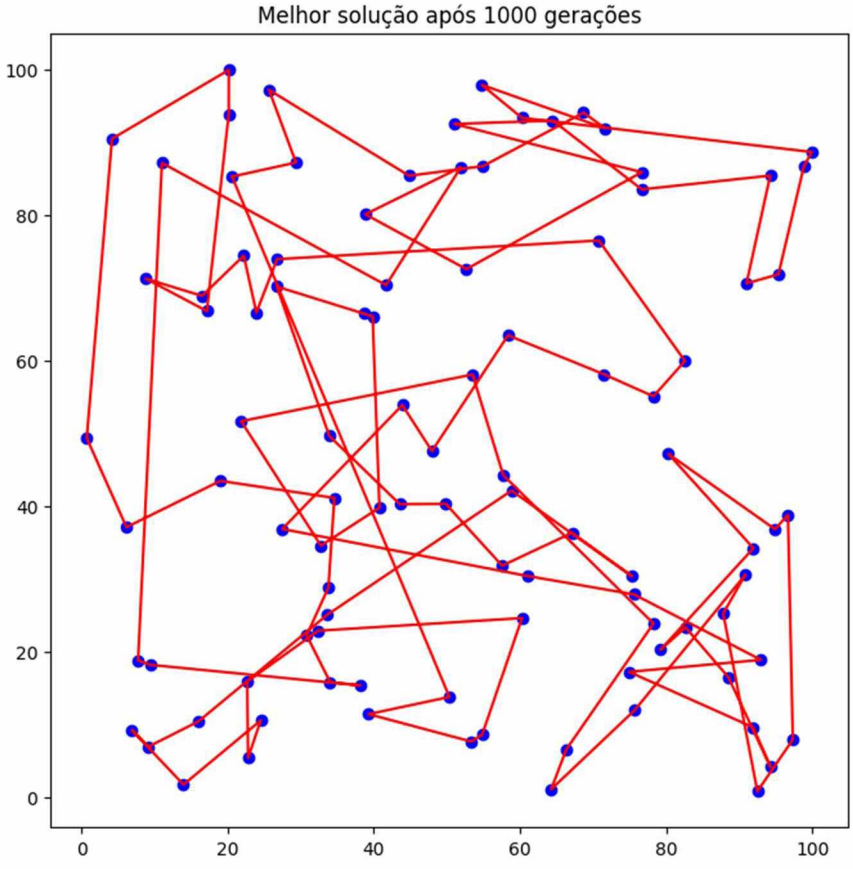
Melhor solução após 1000 gerações
0
20
40
60
80
100

```
## Bibliotecas

import numpy as np
import matplotlib.pyplot as plt
from sklearn.decomposition import PCA
from sklearn.feature_extraction.text import CountVectorizer
from sentence_transformers import SentenceTransformer

## Texto base


textos = [
    "O cachorro correu pelo parque atrás da bola",
    "O cão brincou no parque com sua bola favorita",
    "O gato dormia tranquilamente no sofá da sala",
    "O felino estava descansando calmamente no sofá",
    "Um pássaro voou rapidamente para a árvore mais alta",
    "O drone pousou cuidadosamente no topo da árvore"
]

## Modelo por frequência de palavras, com visualização usando PCA


vectorizer = CountVectorizer()
X_palavras = vectorizer.fit_transform(textos).toarray()
# PCA para visualização (reduzindo a 2 dimensões)
pca_palavras = PCA(n_components=2)
X_pca_palavras = pca_palavras.fit_transform(X_palavras)

# Plot da representação baseada em frequência de palavras
plt.figure(figsize=(8, 6))
plt.scatter(X_pca_palavras[:,0], X_pca_palavras[:,1], color='blue')

for i, texto in enumerate(textos):
    plt.annotate(f'Texto {i+1}', (X_pca_palavras[i,0],
X_pca_palavras[i,1]))

plt.title('Representação Vetorial - Frequência de Palavras (PCA)')
plt.xlabel('PCA Componente 1')
plt.ylabel('PCA Componente 2')
plt.grid(True)
plt.show()
```

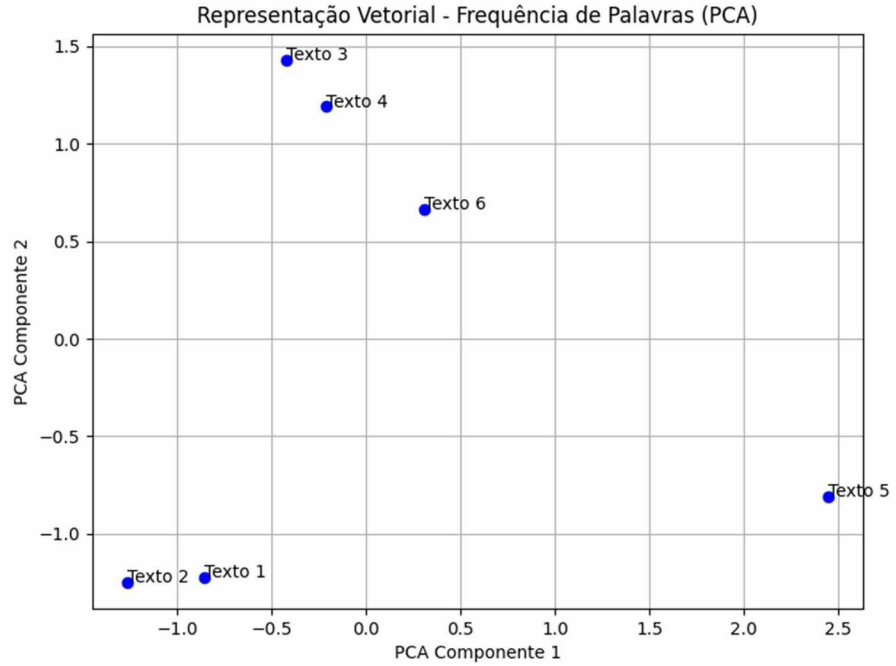


```
### Matrix de similaridade usando coseno

# Similaridade por cosseno
sim_matrix = cosine_similarity(X_pca_palavras)

print("Matriz de similaridade por cosseno entre textos:\n")
print(sim_matrix)

### Avaliação dos resultados similares

pares_similares = np.argsort(-sim_matrix, axis=1)[:, 1]

print("\nTextos mais similares entre si:")
for idx, par in enumerate(pares_similares):
    print(f"Texto {idx+1} é mais próximo do Texto {par+1}")

Textos mais similares entre si:
Texto 1 é mais próximo do Texto 2
Texto 2 é mais próximo do Texto 1
Texto 3 é mais próximo do Texto 4
Texto 4 é mais próximo do Texto 3
Texto 5 é mais próximo do Texto 6
Texto 6 é mais próximo do Texto 4

## Modelo por embedding e visualização usando PCA

# Usando modelo de sentence transformer
https://huggingface.co/sentence-transformers/all-MiniLM-L6-v2
modelo_embed = SentenceTransformer('all-MiniLM-L6-v2')
X_embeddings = modelo_embed.encode(textos)

# PCA para visualização (reduzindo a 2 dimensões)
pca_embed = PCA(n_components=2)
X_pca_embed = pca_embed.fit_transform(X_embeddings)
```

```
# Plot da representação baseada em embeddings de sentenças
plt.figure(figsize=(8, 6))
plt.scatter(X_pca_embed[:,0], X_pca_embed[:,1], color='green')

for i, texto in enumerate(textos):
    plt.annotate(f'Texto {i+1}', (X_pca_embed[i,0],
X_pca_embed[i,1]))

plt.title('Representação Vetorial - Embeddings de Sentenças (PCA)')
plt.xlabel('PCA Componente 1')
plt.ylabel('PCA Componente 2')
plt.grid(True)
plt.show()
```

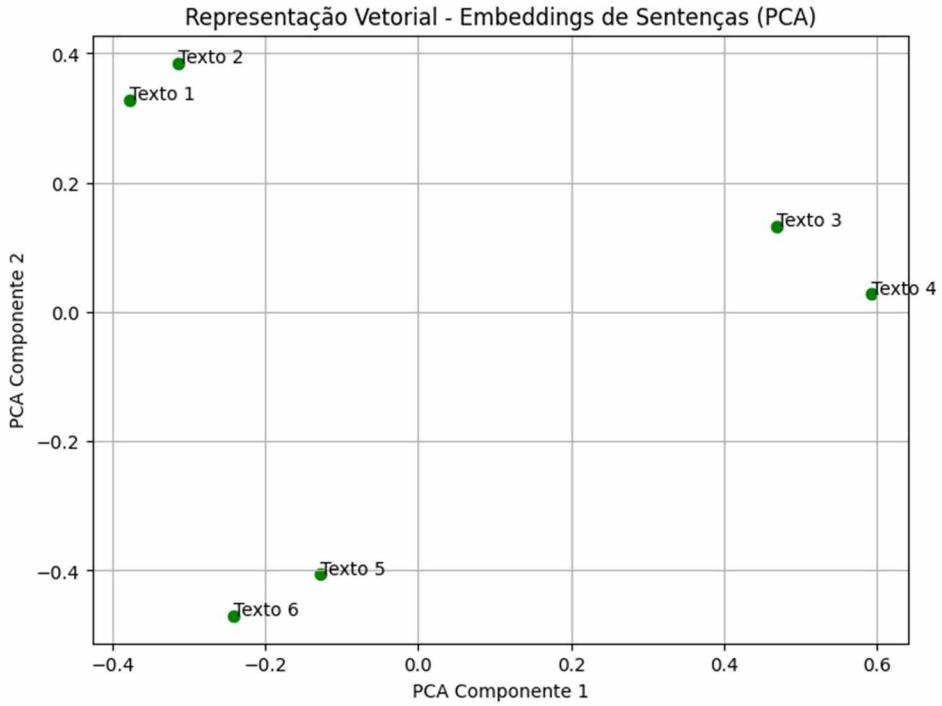


```
### Matrix de similaridade usando coseno

# Similaridade por cosseno
sim_matrix = cosine_similarity(X_pca_embed)

print("Matriz de similaridade por cosseno entre textos:\n")
print(sim_matrix)

### Avaliação dos resultados similares
pares_similares = np.argsort(-sim_matrix, axis=1)[:, 1]

print("\nTextos mais similares entre si:")
for idx, par in enumerate(pares_similares):
    print(f"Texto {idx+1} é mais próximo do Texto {par+1}")


Textos mais similares entre si:
Texto 1 é mais próximo do Texto 2
Texto 2 é mais próximo do Texto 1
```

```
Texto 3 é mais próximo do Texto 4
Texto 4 é mais próximo do Texto 3
Texto 5 é mais próximo do Texto 6
Texto 6 é mais próximo do Texto 5
```