<table>
<tr><td>Título dos encontros</td><td colspan="3">Reconhecendo Caracteres</td><td>Sequência:
17</td></tr>
<tr><td>Etapa/Ano</td><td colspan="4">Ensino Médio: ☑ 1º Ano | ☐ 2º Ano | ☐ 3º Ano</td></tr>
<tr><td>Nível de Maturidade
[link]</td><td>Escola</td><td>☐ Emergente
☑ Básico
☐ Intermediário
☐ Avançado</td><td>Docente</td><td>☑ Básico
☐ Intermediário
☐ Avançado</td></tr>
<tr><td>Competências</td><td colspan="4">☐ C1 ☑ C2 ☑ C3 ☐ C4 ☐ C5</td></tr>
<tr><td>Objetos de Conhecimento</td><td colspan="4">Treinamento de um sistema de IA</td></tr>
<tr><td>Recursos Educacionais</td><td colspan="4">• Projetor
• Marcadores ou canetas
• Computadores com acesso à internet</td></tr>
<tr><td>Componentes Curriculares Relacionados</td><td>☐ Arte
☐ Língua Port.
☐ Ed. Física</td><td>☐ Geografia
☐ História
☐ Matemática</td><td colspan="2">☐ Língua Inglesa
☐ Ciências
☑ Computação</td></tr>
<tr><td>Palavras-chave</td><td colspan="4">Treinamento, Aprendizado de Máquina, Viés</td></tr>
<tr><td>Perguntas Importantes</td><td colspan="4">• Como é uma base de dados de treinamento de imagens?
• Onde podemos aplicar os conceitos de classificação de imagens?
• Como se dá a classificação de imagens de caracteres manuscritos?</td></tr>
<tr><td>Encontros</td><td colspan="2">2</td><td>Total de Horas-aula</td><td>4</td></tr>
<tr><td>Objetivos</td><td colspan="4">• Identificar os sucessos e limitações da IA
• Conhecer o processo de aprendizado supervisionado de máquina</td></tr>
<tr><td>Habilidades Relacionadas</td><td colspan="4">BNCC:
EM13CO10 - Conhecer os fundamentos da Inteligência Artificial, comparando-a com a inteligência humana, analisando suas potencialidades, riscos e limites.

Referencial Curricular IA no EM:
EM01IA06 - Sistemas Preditivos - Compreender como o uso de bases de dados e dicionários permite a criação de Sistemas Preditivos.</td></tr>
<tr><td>Práticas Pedagógicas Inovadoras
[link]</td><td colspan="4">☑ Aula Enriquecida com Tecnologia
☐ Ensino Híbrido: Sala de aula invertida
☐ Ensino Híbrido: rotação por estação
☐ Ensino Híbrido: rotação individual
☑ Aulas Mão na massa
☐ Aprendizagem baseada em projetos</td></tr>
</table>

Sequência Didática - Encontro 1

Introdução - O que é classificação na IA?

A classificação é uma tarefa de aprendizado supervisionado que consiste em prever a categoria ou classe de objetos, indivíduos, informações, etc., baseada em características e dados previamente conhecidos. Essa tarefa é amplamente utilizada em várias aplicações de aprendizado de máquina, onde o objetivo é categorizar itens em um conjunto pré-definido de classes. Por exemplo, se trabalharmos com texto, podemos classificar e-mails entre "Spam" e "Não Spam", analisar qual a conotação foi utilizada em um texto, se foi positiva ou negativa, e até classificar textos por assunto, categorizando artigos, livros, redações, documentos, entre outros.
Esse mesmo contexto pode ser aplicado à imagens. Podemos classificar números e letras que tenham sido escritos à mão ou impressos, reconhecer e identificar faces em imagens (como o Facebook/Instagram fazem ao sugerir a marcação de uma pessoa na foto), distinguir animais de diferentes espécies, bem como objetos distintos. Esse último, identificar objetos, é muito importante nos sistemas de condução autônoma, onde a todo instante o sistema precisa detectar pessoas, veículos, sinalização de trânsito, entre outras coisas, para se guiar.

Quando estamos elaborando um sistema de detecção de objetos utilizando inteligência artificial, precisamos decidir qual método iremos utilizar e qual será a nossa base de dados de treinamento. Felizmente, a linguagem Python possui uma série de bibliotecas (conjunto de funcionalidades) prontas para trabalhar com IA. Essas bibliotecas disponibilizam diversos métodos de aprendizado que podem ser adaptados a diferentes contextos. Apenas para ilustrar, podemos citar alguns nomes (que não necessitamos conhecer em detalhes), como TensorFlow, PyTorch, Scikit-learn, entre outras. Dentre as bases de dados de treinamento, podemos criar nossa própria base de dados coletando imagens padronizadas do nosso interesse, ou podemos utilizar uma base de dados conhecida. O MNIST (*Modified National Institute of Standards and Technology database* - Banco de dados modificado do Instituto Nacional de Padrões e Tecnologia em tradução livre) disponibiliza um conjunto de imagens de numerais manuscritos com tamanho de 28x28 pixels[1], que podem ser utilizadas para comparar a qualidade dos algoritmos desenvolvidos.

A Base de Dados MNIST

A base de dados MNIST é um dos conjuntos de dados mais conhecidos pela comunidade que trabalha com aprendizado de máquina, pois ela permite testar algoritmos de reconhecimento de dígitos. Ela contém imagens de dígitos escritos à mão, variando de 0 a 9, e é frequentemente usada como ponto de partida para algoritmos mais complexos de classificação de imagem. Essa base de dados possui 60 mil imagens para treinamento e 10 mil imagens para testes. Em outras palavras, temos disponível um conjunto de 60 mil imagens de numerais manuscritos, junto de sua respectiva classificação correta, a fim de utilizarmos para criar e treinar nosso modelo. Além

[1] Uma imagem de 28x28 pixels é uma imagem muito pequena. Em comparação, os monitores Full HD possuem 1920x1080 pixels.

disso, ela disponibiliza outras 10 mil imagens (diferentes das primeiras), onde podemos avaliar se nosso modelo consegue se sair suficientemente bem quando aplicado a imagens que ele nunca viu. A seguir, temos uma imagem que mostra alguns números.

Figura 1. Amostras do MNIST. Fonte: https://pt.wikipedia.org/wiki/Banco_de_dados_MNIST

Esses números manuscritos são disponibilizados junto de sua classe, conforme pode ser visto na imagem a seguir.

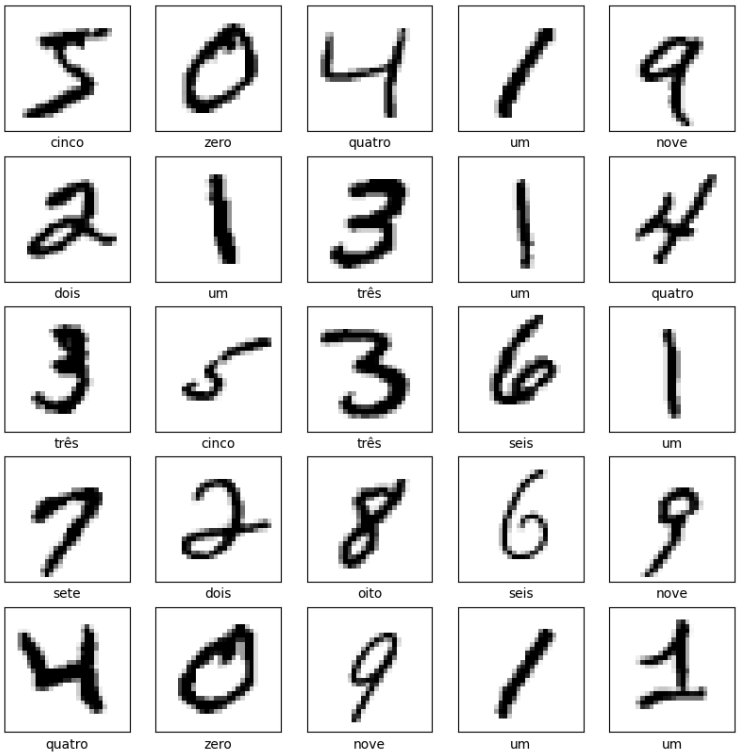

Figura 2. Número e suas classes. Fonte: Os Autores

Podemos observar que as imagens são todas diferentes entre si, por mais que representem a mesma classe. Essas características fazem com que não tenhamos um formato padrão e nem uma forma ideal de representar um número, exigindo que os métodos lidem adequadamente com essas variações.

Atividade - Desenhista

Essa atividade simula o processo de reconhecimento de imagens, semelhante ao desafio enfrentado pelos algoritmos ao trabalhar com a biblioteca MNIST. O foco é entender como características visuais claras e distintas são cruciais para o reconhecimento eficiente de padrões, seja por humanos ou máquinas.

Materiais Necessários:

- Quadro branco ou lousa
- Marcadores ou giz
- Cronômetro ou relógio
- Cartões com imagens ou papéis com nomes de objetos simples

Procedimento:

1. Divida a classe em grupos e prepare cartões que tenham imagens de objetos simples que podem ser facilmente desenhados e reconhecidos, como uma casa, árvore, carro, sol, etc. Esses objetos simulam a simplicidade dos dígitos em MNIST, que são claros e distintos. Também defina um limite de tempo para cada rodada de desenho (por exemplo, 1 minuto).
2. Início da Atividade: Um aluno de cada vez vai ao quadro. Este aluno pode escolher um cartão (se estiver usando) ou pensar em um objeto simples para desenhar.
3. Desenho e Adivinhação: O aluno começa a desenhar o objeto no quadro. Nenhum detalhe verbal ou gestual pode ser usado para ajudar na adivinhação. Os outros grupos observam o desenho e tentam adivinhar o que está sendo desenhado o mais rápido possível. O primeiro grupo a adivinhar corretamente ganha um ponto.
4. Rotação: Após cada aluno ter uma chance de desenhar, o próximo aluno do grupo vai para o quadro. Continue até que desejar.
5. Discussão: Ao final da atividade, discuta as estratégias usadas pelos alunos tanto para desenhar quanto para adivinhar. Pergunte como a clareza do desenho afetou a facilidade de adivinhação. Compare isso com a necessidade de dados claros e bem formatados para treinar modelos de aprendizado de máquina eficientemente.

Relação com o MNIST: Explique que, assim como precisavam de desenhos claros e reconhecíveis para adivinhar corretamente, os algoritmos de aprendizado de máquina precisam de dados bem definidos e consistentes, como os dígitos manuscritos da MNIST, para realizar tarefas de reconhecimento de padrões com sucesso.	
Avaliação	Os alunos podem ser avaliados de acordo com sua interação e participação nas atividades e discussões.
Material Complementar	**MNIST na Wikipedia:** https://pt.wikipedia.org/wiki/Banco_de_dados_MNIST **Base de dados MNIST na biblioteca Keras:** https://keras.io/api/datasets/mnist/ **Diferentes bases de dados similares à base MNIST:** https://keras.io/api/datasets/

Sequência Didática - Encontro 2

Orientações Gerais

Para essa atividade, compartilhamos um mesmo material em diferentes formatos, de modo a facilitar seu uso. Temos um arquivo detalhado, com o passo a passo do que está acontecendo com o algoritmo. Para rodar esse programa, cada bloco precisa ser executado em sequência.

> 🐍 Vide o código “Atividade Prática no Google Colaboratory - com Comentários” no material complementar para saber mais.

Contudo, isso pode acabar confundindo quem não tem afinidade nenhuma com o Google Colaboratory. Como toda a explicação da atividade está descrita abaixo, também disponibilizamos um material mais objetivo onde, com 1 clique, todo o algoritmo dessa atividade poderá ser executado.

> 🐍 Vide o código “Atividade Prática no Google Colaboratory - Completo” no material complementar para saber mais.

Introdução

Após conhecermos os conceitos básicos teóricos acerca da base de dados MNIST, vamos ver como criamos uma aplicação em Python para reconhecer os números. Para isso, iremos criar

uma rede neural simples com base no tutorial disponível no site da biblioteca Keras[2]. Para isso, vamos dividir a atividade nos seguintes passos:

1. Obtenção da Base de Dados
2. Criação do Modelo
3. Treinamento
4. Validação

Esses passos podem ser utilizados, de forma geral, para qualquer atividade de criação de um modelo preditivo. No primeiro passo, temos que definir quais são os dados que iremos utilizar no treinamento do modelo e nos testes. Depois, no passo 2, precisamos definir como será o algoritmo de aprendizado de máquina, no nosso caso, será uma rede neural artificial, mas poderia ser uma árvore de decisão, por exemplo. Em seguida, precisamos treinar o modelo (passo 3), onde iremos ajustar os pesos da nossa rede passando para ela as imagens da nossa base de dados. Por fim, no passo 4, iremos avaliar a qualidade do modelo que criamos.

Atividade - Vamos Classificar Numerais

Tendo em mente os passos acima, vamos criar nosso modelo de classificação de numerais manuscritos utilizando uma rede neural e a biblioteca MNIST. O primeiro passo que temos que realizar é a importação da base de dados. Este guia usa o dataset MNIST, que contém 60 mil imagens em escala de cinza, em 10 categorias. As imagens mostram os numerais de 0 a 9 individuais com resolução baixa (28x28 pixels), conforme visto aqui:

[2] A biblioteca Keras possui um conjunto de ferramentas e base de dados que podem ser facilmente utilizados para criar os modelos.

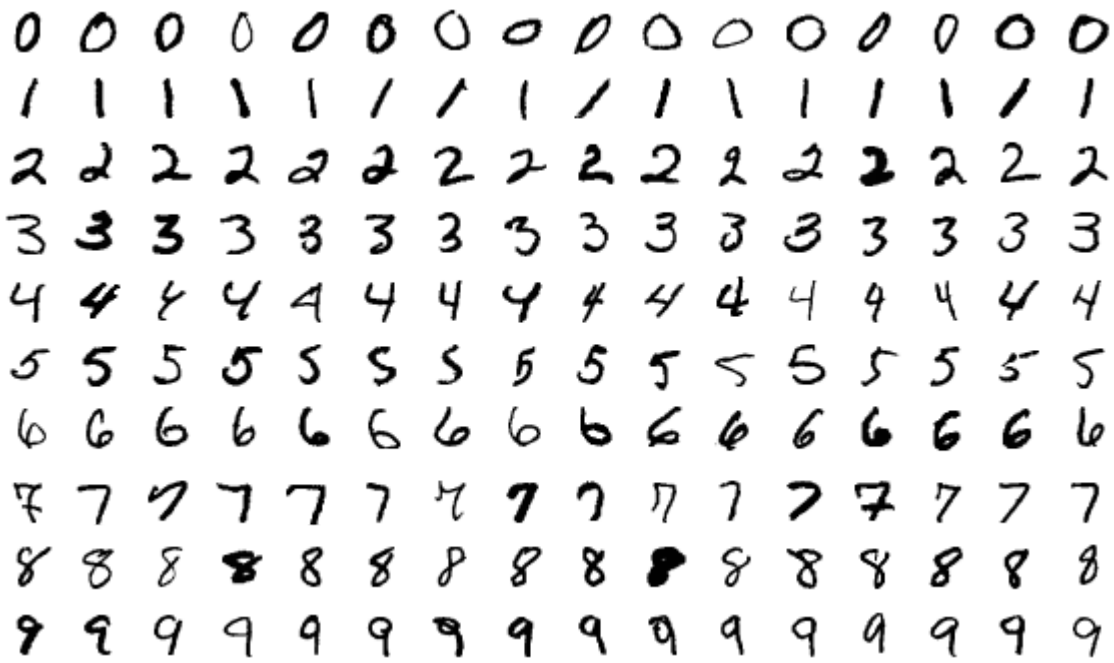

Imagem 1. Amostras do MNIST.

O MNIST é uma base de dados utilizada por muitos iniciantes, sendo considerado os primeiros passos dos programas de aprendizado de máquina para visão computacional. O dataset MNIST contém imagens de dígitos escritos à mão (0, 1, 2, etc.).

Ao carregar a base de dados, são retornados dois conjuntos. O primeiro armazena as 60 mil imagens e as classes a qual cada imagem pertence. O mesmo acontece para o segundo conjunto, que armazenam as 10 mil imagens de teste, utilizadas para calcular a precisão do modelo.

As imagens podem ser entendidas como matrizes, tendo 28x28 linhas e colunas, sendo que os valores de cada célula equivalem a um pixel, variando de 0 a 255. Os rótulos (ou classes) representam qual número a imagem descreve, variando de 0 a 9:

Rótulo	Classe
0	zero
1	um
2	dois
3	tres
4	quatro
5	cinco
6	seis
7	sete
8	oito
9	nove

Cada imagem representa apenas um único número entre 0 e 9.

Após termos a base de dados definida e carregada, vamos criar a rede neural artificial que iremos utilizar para tentar identificar quais numerais aparecem nas imagens. Como estamos trabalhando com uma imagem que possui 28x28 pixels, essa imagem se parece muito com a representação da tabela abaixo.

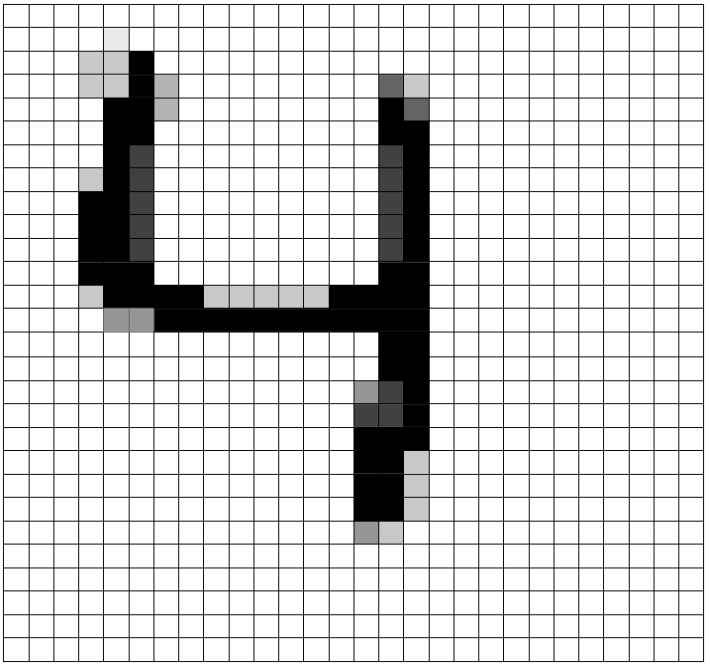

Uma imagem é composta por pixels. Cada pixel possui um conjunto de cores. No caso de imagens em preto e branco, essas imagens possuem 1 único valor por pixel, variando de 0 a 255, sendo 0 preto absoluto e 255 branco absoluto (vide imagem a seguir). A variação desses valores permitem a criação de tonalidades diferentes de cinza. A representação acima mostra um numeral 4 após ter sido transformado em imagem.

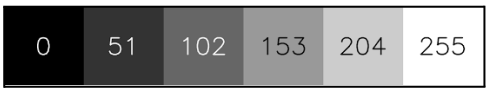

Nesse sentido, nossa rede neural terá um conjunto inicial de 784 neurônios (28 * 28), onde cada neurônio representa o valor de cada pixel da imagem. Em seguida, teremos um conjunto de 128 neurônios (determinado de forma arbitrária) que se ligam a todos os 784 neurônios iniciais. Por fim, teremos um último conjunto de 10 neurônios, onde cada neurônio representa um possível rótulo, terminando qual numeral aquela classe pertence. De forma prática, a imagem entra na forma de números através do primeiro conjunto de neurônios, passa para o segundo conjunto, onde diversas operações matemáticas são realizadas e chegam ao final, no último conjunto, onde apenas 1 neurônio (dos 10 finais) será ativado, determinando qual numeral aquela imagem representa.

Mas, para que isso possa funcionar adequadamente, é necessário realizar o treinamento do modelo. O treinamento da modelo de rede neural requer os seguintes passos:

- Alimentar os dados de treinamento no modelo.
- O modelo aprende a associar imagens e rótulos.
- Você pede para o modelo fazer previsões sobre um conjunto de testes.
- Verifique se as previsões correspondem aos rótulos adequados.

Por fim, temos que avaliar o desempenho do modelo. Essa avaliação consiste em utilizarmos o conjunto de dados de teste (que não foram usados no treinamento) e calcular o percentual de acerto do modelo. Na imagem a seguir, podemos ver as imagens ao lado de um gráfico de barras, onde as barras azuis mostram o percentual de probabilidade daquela imagem pertencer a determinada classe. Por exemplo, ao olharmos a primeira imagem (da esquerda para direita, de cima para baixo), observamos o numeral 7, sua legenda sendo sete (100%) e uma barra azul no gráfico ao lado junto do rótulo 7. Isso demonstra que o numeral 7 desta imagem em questão foi classificado como pertencendo ao rótulo 7. Similarmente, podemos observar a terceira imagem da terceira fileira, onde não é tão fácil determinarmos se o numeral da imagem realmente é o numeral 5. Dada a dificuldade, o modelo previu que seria o numeral 5 com 61% de probabilidade, indicando que é difícil para as redes neurais artificiais identificarem certos manuscritos. Analisando o gráfico ao lado, pode-se observar que a rede sugere que esse numeral poderia ser um 2, um 6 ou até um 9.

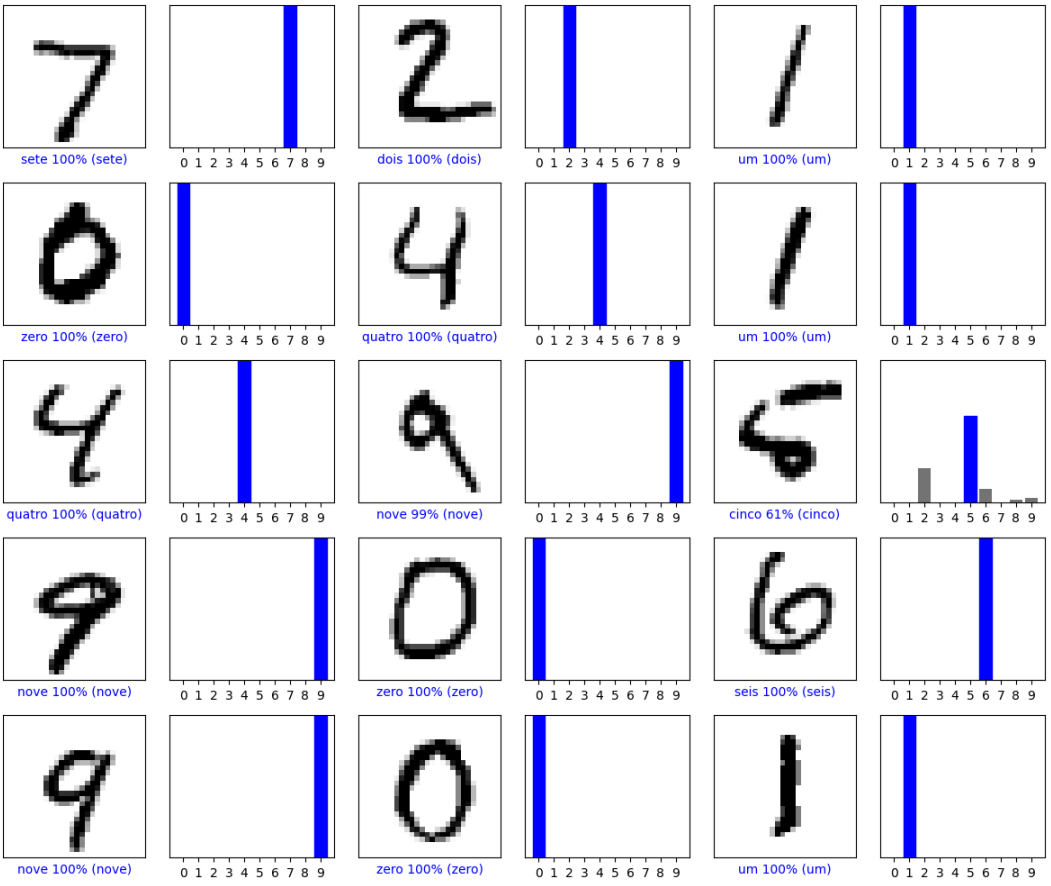

Para ter acesso ao algoritmo apresentado aqui no plano, entre na “Atividade Prática no Google Colaboratory”, disponível no material complementar e execute os passos para que possam observar o modelo sendo criado em tempo real.	
Avaliação	Os alunos podem ser avaliados de acordo com sua interação e participação no ambiente de programação.
Material Complementar	**Atividade Prática no Google Colaboratory - com Comentários** https://colab.research.google.com/drive/1rWuJ8Qts2G4Acc2UkJcHU-_aMJEEiaOb?usp=sharing **Atividade Prática no Google Colaboratory - Completo** https://colab.research.google.com/drive/1dzmDD-DH_eHXB4OJkxnZjSp260jAsmRl?usp=sharing **Treine sua primeira rede** https://www.tensorflow.org/tutorials/keras/classification?hl=pt-br **Exemplo de Algoritmos em Linguagem Python - Linguagens de IA** https://colab.research.google.com/drive/1vwMhN9sg6wATLS-j04HvmigHRxuwOBhH?usp=sharing