


Raspberry Pi
Foundation

Experience AI

Glossário de
termos de IA



Experience AI - Glossário de termos

Este glossário explica os principais termos de inteligência artificial (IA) e aprendizado de máquina (ML) usados nas [Lições de IA do Experience](#) e além.

[Ir para o glossário](#)

Elaboramos estas explicações principalmente para professores e educadores, tendo em mente um público jovem. Com este glossário, pretendemos ajudá-lo a consolidar sua compreensão desses termos-chave, bem como o seu conhecimento técnico.

O vocabulário é uma parte importante do ensino e da aprendizagem. O uso correto do vocabulário pode ajudar os alunos a desenvolverem sua compreensão, enquanto seu uso inconsistente pode levar a concepções alternativas (concepções equivocadas) que podem interferir na aprendizagem dos alunos. Você pode ler mais sobre isso em [nossa Pedagogia Leitura rápida sobre concepções alternativas](#). Como professor, usar vocabulário técnico e preciso de forma regular e consistente pode auxiliar na compreensão conceitual dos alunos.

Utilizamos a teoria das 'ondas semânticas' para nos ajudar a escrever as explicações. Cada explicação segue a mesma estrutura em três partes: a primeira apresenta uma explicação mais abstrata do termo; a segunda explora o significado do termo por meio de um exemplo comum; e a terceira reconstrói o que foi explicado no exemplo em termos novamente mais abstratos, para retomar e reforçar o vocabulário. Você pode encontrar mais informações em [nossa Pedagogia Leitura Rápida sobre ondas semânticas](#).

Esta é a versão 1 do glossário. Este glossário será complementado, revisado e atualizado à medida que as lições do Experience AI evoluírem.

Índice

[Aprendizado de Máquina](#)
[Aprendizado não supervisionado](#)
[Aprendizado por reforço](#)
[Aprendizado supervisionado](#)
[Árvore de decisão](#)
[Baseado em regras](#)
[Característica](#)
[Cartão de Modelo](#)
[Ciclo de vida de um projeto de IA](#)
[Classe](#)
[Classificação](#)
[Confiança](#)
[Dados de teste](#)
[Dados de treinamento](#)
[Dados](#)
[Explicabilidade](#)
[IA generativa](#)
[Inteligência Artificial](#)
[Letramento em IA](#)
[Limiar de confiança](#)
[Limpeza de dados](#)
[Modelo](#)
[Nó de árvore de decisão](#)
[Orientado a dados](#)
[Precisão](#)
[Previsão](#)
[Rótulo](#)
[Treinamento](#)
[Viés de dados](#)
[Viés social](#)
[Viés](#)
[Visão computacional](#)

Aprendizado de Máquina

Aprendizado de máquina (ML) é uma abordagem usada para projetar e construir sistemas de **inteligência artificial (IA)**. O aprendizado de máquina (ML) “aprende” ao usar exemplos na forma de **dados**, em vez de executar instruções passo a passo. Em outras palavras, aplicações de aprendizado de máquina são **orientados a dados**. Por exemplo, uma aplicação de aprendizado de máquina é usada para reconhecer a fala. Ela é baseada em muitos exemplos de pessoas falando com diferentes sotaques e tons de voz. Outras aplicações de aprendizado de máquina incluem a identificação de objetos em imagens ou a execução de jogos complexos. Cada aplicação de aprendizado de máquina é projetada para resolver um problema específico.

Aprendizado não supervisionado

O aprendizado não supervisionado é uma abordagem usada para **treinar modelos de aprendizado de máquina (ML)**. Desenvolvedores treinam modelos de aprendizado não supervisionado para organizar **dados** com base em similaridades. Esse processo resulta na descoberta de padrões ocultos nos dados. Um tipo de aprendizado não supervisionado é o agrupamento. Um exemplo de problema de agrupamento é **prever** como dados de saúde podem ser agrupados para ajudar no diagnóstico de doenças. Esses grupos são chamados de agrupamentos, que não são conhecidos de antemão. O modelo de aprendizado de máquina pode ser usado para prever se novos dados de saúde se enquadram em um dos grupos. As abordagens de aprendizado não supervisionado podem ser úteis para resolver problemas nos quais as pessoas podem não saber o que procurar.

Aprendizado por reforço

O aprendizado por reforço é uma abordagem usada para **treinar modelos de aprendizado de máquina (ML)**. Essa abordagem é utilizada para resolver problemas com um objetivo claro, no qual recompensas e penalidades são usadas para atingir esse objetivo. As abordagens de aprendizagem por reforço são utilizadas no projeto de carros autônomos ou para jogar jogos complexos. Por exemplo, um modelo de aprendizado por reforço pode ser usado para projetar um aplicativo para jogar xadrez. O modelo é treinado para **prever** os movimentos que maximizam as recompensas e minimizam as penalidades em direção à vitória. As abordagens de aprendizagem por reforço utilizam recompensas e penalidades para identificar estratégias para atingir um objetivo definido.

Aprendizado supervisionado

O aprendizado supervisionado é uma abordagem usada para **treinar modelos de aprendizado de máquina (ML)**. Abordagens de aprendizado supervisionado utilizam grandes quantidades de **dados rotulados** por pessoas com informações relevantes. Um tipo de aprendizado supervisionado é a **classificação**. Um exemplo de problema de classificação é a identificação de tigres na natureza. Os dados consistem em muitas imagens, sendo que aquelas que contêm tigres estão devidamente identificadas.

O modelo de ML é treinado com as imagens rotuladas e **prevê** se há um tigre nestas imagens. Ter imagens corretamente rotuladas permite ao desenvolvedor saber até que ponto as previsões do modelo são **precisas** e adaptar o treinamento do modelo. Em seguida, o modelo de aprendizado de máquina pode ser usado para prever se há um tigre em imagens completamente novas. As abordagens de aprendizado supervisionado dependem da existência de dados rotulados corretamente em quantidade suficiente para produzir previsões precisas.

Árvore de decisão

Uma árvore de decisão de **aprendizado de máquina (ML)** é um tipo de **modelo** de ML. Desenvolvedores de ML usam árvores de decisão para estruturar um conjunto de condições com base nas quais uma **previsão** pode ser feita. As condições são derivadas de **características** nos **dados**. Por exemplo, uma árvore de decisão pode ser usada para construir um sistema de recomendação de filmes. O modelo de árvore de decisão é **treinado** usando as preferências de filmes de muitas pessoas. Durante o treinamento, as condições são geradas com base em características como o tipo de filme, a duração ou o ator principal. O modelo gera uma previsão de qual filme alguém pode gostar de assistir em seguida, com base em como suas preferências se encaixam nas condições do modelo. A estrutura das árvores de decisão é gerada com base em grandes quantidades de dados e pode mudar se for retreinada com dados diferentes.

Baseado em regras

O modelo baseado em regras é uma forma de projetar sistemas usando um conjunto de regras predefinidas. Por exemplo, um programa de jogo da velha é projetado usando regras sobre quais movimentos devem ser feitos para tentar ganhar o jogo. As regras são definidas por humanos, que geralmente são especialistas na área do problema que está sendo resolvido. **Sistemas de inteligência artificial (IA)** construídos usando uma abordagem baseada em regras também são conhecidos como 'a boa e velha IA'. Sistemas baseados em regras contrastam com sistemas **orientados a dados** onde **dados** são usados como exemplos de como resolver o problema. Sistemas baseados em regras são úteis para resolver problemas nos quais regras que abrangem a maioria das situações podem ser criadas e seguidas.

Característica

No **aprendizado de máquina (ML)**, características representam propriedades associadas aos **dados**. Por exemplo, um conjunto de dados musicais pode ter características como andamento, tom, energia ou gênero. Alguns **modelos** de aprendizado de máquina são **treinados** usando características para encontrar semelhanças nos dados. Outros **preveem** novas características nos dados que as pessoas não conseguem observar facilmente. A escolha das características a serem usadas no treinamento de um modelo de aprendizado de máquina pode fazer toda a diferença no desempenho do modelo.

Cartão de Modelo

Um cartão de modelo de **aprendizado de máquina (ML)** é uma forma de documentar informações essenciais sobre **modelos** de aprendizado de máquina de maneira estruturada. Os cartões de modelos são escritos por desenvolvedores de aprendizado de máquina, tanto para especialistas quanto para não especialistas. Por exemplo, um aplicativo de aprendizado de máquina é desenvolvido para traduzir diferentes idiomas, como do árabe para o francês e vice-versa. Um cartão de modelo inclui informações sobre a **precisão** de tradução do modelo, bem como o desempenho deste em relação a jargões, gírias e dialetos. Outras informações do cartão do modelo podem incluir o tipo de modelo de ML, diferentes indicadores de desempenho e até mesmo **vieses** conhecidos. Os cartões de modelo são criados durante a etapa de explicação do **ciclo de vida de um projeto de IA** para expor informações sobre as capacidades e limitações do modelo, de uma forma fácil de entender.

Ciclo de vida de um projeto de IA

O ciclo de vida de um projeto de **inteligência artificial (IA)** refere-se às diferentes etapas que podem ser seguidas para projetar e construir um **modelo de aprendizado de máquina (ML)**. As etapas incluem definir o problema, preparar os **dados**, **treinar** o modelo, testar o modelo, avaliar o modelo e explicar o modelo. Por exemplo, um modelo de aprendizado de máquina é projetado para gerar novas listas de reprodução de músicas. Um desenvolvedor de aprendizado de máquina pode primeiro considerar que tipo de lista de reprodução deseja criar. Em seguida, eles podem coletar e preparar dados sobre as músicas. O modelo de aprendizado de máquina é treinado e testado com os dados de música. O modelo de aprendizado de máquina é avaliado para verificar se funciona conforme o esperado. Por fim, o modelo de aprendizado de máquina é explicado para que outros possam utilizá-lo. Normalmente, as etapas do ciclo de vida de um projeto de IA são usadas de forma iterativa, em vez de uma após a outra. O ciclo de vida de um projeto de IA é uma série de etapas iterativas usadas para construir e aprimorar um modelo de aprendizado de máquina.

Classe

Para **treinar modelos de classificação**, desenvolvedores de **aprendizado de máquina (ML)** organizam os **dados** em grupos predefinidos chamados classes. As classes são definidas antecipadamente com base no que as pessoas consideram útil para agrupar as coisas. Imagine um aplicativo de aprendizado de máquina projetado para identificar frutas em um supermercado. Os dados podem ser organizados em classes como maçãs, bananas, laranjas, mirtilos, etc. Uma classe é um grupo de elementos que os modelos de classificação usam para identificar semelhanças nos dados.

Classificação

Classificação refere-se à tarefa de atribuir elementos a grupos predefinidos, chamados **classes**. As classes são definidas antecipadamente com base no que as pessoas consideram útil para agrupar as coisas. Um exemplo de problema de classificação é a análise de sentimentos em

resenhas de músicas. Um **modelo** de classificação de **aprendizado de máquina (ML)** é **treinado** com avaliações **rotuladas** por pessoas como 'positivas' ou 'negativas'. Após o treinamento, o modelo de aprendizado de máquina pode ser usado para **prever** se uma nova avaliação deve ser classificada como 'positiva' ou 'negativa'. Um modelo de classificação prevê um ou mais rótulos de classe. Uma abordagem de classificação é útil para resolver problemas em que a resposta se enquadra em grupos predefinidos.

Confiança

Confiança refere-se ao grau de certeza que se tem sobre algo. No **aprendizado de máquina (ML)**, confiança é uma forma de medir o grau de certeza de uma **previsão**. Por exemplo, um modelo de classificação é projetado para prever se vai chover amanhã. O modelo prevê com 90% de confiança que haverá chuva amanhã. Em outras palavras, há 90% de certeza de que amanhã vai chover. Utilizar a confiança para medir a certeza das previsões ajuda a avaliar a qualidade de um modelo de aprendizado de máquina.

Dados de teste

Em **aprendizado de máquina (ML)**, dados de teste referem-se aos **dados** usados para testar e avaliar **modelos** de aprendizado de máquina **treinados**. Por exemplo, um modelo de ML é treinado para **prever** um diagnóstico de uma condição médica. Antes de ser utilizado em situações reais, o modelo é testado e avaliado usando dados de teste. Os dados de teste são separados dos **dados de treinamento** com os quais um modelo de aprendizado de máquina (ML) é treinado. Os dados de teste são usados para medir o desempenho de um modelo de aprendizado de máquina com exemplos que vão além dos dados de treinamento.

Dados de treinamento

No **aprendizado de máquina (ML)**, **dados** de treinamento referem-se aos exemplos na forma de dados usados para **treinar modelos** de aprendizado de máquina. Desenvolvedores constroem modelos para identificar padrões nos dados de treinamento, que podem ser usados para gerar **previsões** sobre novos dados. Por exemplo, um desenvolvedor cria um aplicativo de reconhecimento de fala. Os dados de treinamento podem incluir muitos exemplos de pessoas falando, com diferentes sotaques ou tons de voz. Quanto mais os dados de treinamento representarem a realidade, melhor será o desempenho do modelo.

Dados

Dados referem-se a valores, medições, fatos ou observações em um formato adequado para serem processados por programas de computador. Existem muitos tipos de dados, como texto, imagem ou som. Um exemplo de dados textuais são as mensagens que as pessoas trocam com seus amigos em dispositivos digitais. No **aprendizado de máquina (ML)**, dados representam os exemplos com os quais os **modelos** de ML são **treinados**. Coletar, **limpar** e estruturar grandes volumes de dados é uma parte essencial do desenvolvimento de modelos de aprendizado de máquina.

Explicabilidade

Explicabilidade refere-se ao grau em que algo pode ser compreendido. No **aprendizado de máquina (ML)**, a explicabilidade ajuda as pessoas a entender como uma **previsão** foi produzida. Por exemplo, os **modelos de árvore de decisão** de ML são explicáveis porque os **nós** podem ser analisados de uma forma que as pessoas possam entender. A maioria dos modelos de aprendizado de máquina não são totalmente explicáveis, e alguns são mais explicáveis do que outros. Aumentar a explicabilidade de um modelo pode ajudar a corrigir problemas e combater **viés**.

IA generativa

IA generativa é um tipo de inteligência **aartificial (IA)** projetado para gerar conteúdo, como texto, imagens ou som. Existem muitos aplicativos que utilizam IA generativa, incluindo aqueles que fazem a produção de arte ou música, ou a geração de texto para chatbots. Por exemplo, aplicativos de arte de IA generativa podem gerar uma imagem com base em um comando, como "faça um desenho de um dragão lendo um livro". A arte de IA generativa é criada usando **modelos de aprendizado de máquina treinados** com milhões de imagens de obras de arte existentes. As imagens resultantes podem reproduzir o estilo de um artista, sem que o artista original saiba ou aprove. Os aplicativos de IA generativa estão se tornando cada vez mais comuns e, muitas vezes, é impossível perceber que ela está sendo usada.

Inteligência Artificial

Inteligência artificial (IA) é o projeto e o estudo de sistemas que aparentam imitar o comportamento inteligente. Alguns aplicativos de IA são baseados em regras. Hoje em dia, os aplicativos de IA são mais frequentemente desenvolvidos utilizando **aprendizado de máquina**, que 'aprende' a partir de exemplos na forma de **dados**. Por exemplo, algumas aplicações de IA são desenvolvidos para responder a perguntas ou ajudar no diagnóstico de doenças. Outras aplicações de IA poderiam ser desenvolvidos para fins nocivos, como a disseminação de notícias falsas. Aplicações de IA não pensam. Aplicativos de IA são desenvolvidos para executar tarefas de uma forma que pareça inteligente.

Letramento em IA

Letramento em IA é um conjunto de competências e formas de pensar que permitem às pessoas interagir de maneira significativa com **aplicativos de inteligência artificial (IA)**, bem como em situações em que esses aplicativos são utilizados ao seu redor. Essas competências incluem compreender a IA, estar envolvido no desenvolvimento de sistemas de IA e ter opiniões fundamentadas sobre as formas como os sistemas de IA são utilizados no mundo. Por exemplo, uma pessoa utiliza o letramento em IA quando avalia a precisão das informações fornecidas por um aplicativo de chatbot com IA. Além das diferentes formas de interação com aplicativos de IA, o letramento em IA inclui o potencial das pessoas para participar ativamente na decisão de como os sistemas de IA podem ser usados ao seu redor

Limiar de confiança

Limiar de confiança refere-se a um valor definido como nível de aceitação para as **previsões** de um **modelo de aprendizado de máquina (ML)**. O limiar de confiança é escolhido pelo desenvolvedor de aprendizado de máquina ao projetar o modelo. Por exemplo, uma previsão é gerada por um modelo de ML com 50% de **confiança** de que haverá uma tempestade de neve amanhã. No entanto, se o limite de confiança for definido em 60%, essa previsão será considerada imprecisa. Em outras palavras, a menos que a confiança da previsão seja de 60% ou mais, ela não será aceita como **precisa**. O valor é definido de acordo com a natureza do problema a ser resolvido, sendo que as previsões de diagnóstico médico exigem um limiar de confiança mais elevado do que as recomendações de músicas. A escolha do limiar determina o que é um nível aceitável de confiança na previsão.

Limpeza de dados

Limpeza de dados é uma etapa da preparação dos **dados** utilizados para **treinar um modelo de aprendizado de máquina (ML)**. A limpeza de dados envolve a identificação e correção de erros nos dados. Por exemplo, corrigir erros de digitação ou remover duplicatas em dados de texto são duas tarefas simples de limpeza de dados. Na maioria das vezes, os dados são desorganizados e exigem uma limpeza mais complexa antes de serem usados para treinar modelos de aprendizado de máquina. Existem muitas maneiras de limpar dados, dependendo do problema e dos tipos de dados. Usar dados limpos é essencial para construir modelos de aprendizado de máquina **precisos**.

Modelo

Um modelo de **aprendizado de máquina (ML)** é usado por uma aplicação de aprendizado de máquina para realizar uma tarefa ou resolver um problema. O modelo é uma representação do problema que está sendo resolvido. Desenvolvedores de aprendizado de máquina usam grandes quantidades de **dados** representativos de um problema específico para **treinar** um modelo a detectar padrões. O resultado do treinamento é um modelo, que é usado para fazer **previsões** sobre novos dados no mesmo contexto. Por exemplo, carros autônomos são construídos usando modelos de aprendizado de máquina para prever quando parar. Os modelos são treinados usando milhões de exemplos de situações em que os carros precisam parar. Existem diferentes tipos de modelos, que utilizam tipos de dados distintos e diferentes métodos de treinamento. Todos os modelos de aprendizado de máquina são treinados para detectar padrões nos **dados de treinamento** de modo a fazer previsões sobre novos dados.

Nó de árvore de decisão

Uma **árvore de decisão** de **aprendizado de máquina (ML)** é composta por nós. Os nós são ligados para formar uma estrutura com base na qual uma **previsão** pode ser gerada. Existem dois tipos de nós: nós de decisão e nós folha. Por exemplo, considere uma árvore de decisão construída para prever os tipos de estrelas em nosso sistema solar. Os nós de decisão representam **características**

dos **dados** como a temperatura, raio, cor ou brilho das estrelas. Os nós folha representam os tipos de estrelas na forma de **rótulos** de previsão, como 'Anã Vermelha', 'Anã Branca' ou 'Anã Marrom'. Os nós da árvore de decisão formam a estrutura necessária para um **modelo** de ML gerar uma previsão.

Orientado a dados

Orientado a dados é uma forma de projetar sistemas utilizando **dados** em vez de instruções passo a passo. Por exemplo, saber o que causa certas doenças é difícil, mas existem muitos dados de exemplo. Portanto, os projetistas utilizam os dados médicos das pessoas afetadas pela doença para diagnosticá-la. Sistemas orientados a dados contrastam com sistemas **baseados em regras**. Sistemas orientados a dados são adequados para resolver problemas quando é difícil criar regras que abranjam todas as situações. Em vez disso, podem ser coletados exemplos suficientes para fundamentar uma solução.

Precisão

Precisão refere-se ao quão correto algo é. No **aprendizado de máquina (ML)**, a precisão é uma forma de medir com que frequência um **modelo** de ML está fazendo uma **previsão** correta. Por exemplo, um modelo de **classificação** é projetado para classificar maçãs. De 100 imagens de maçãs, 90 foram classificadas corretamente. A precisão da classificação do modelo é de 90%. A precisão é uma das maneiras de avaliar modelos de aprendizado de máquina. Na maioria das vezes, a precisão é usada juntamente com outras métricas para avaliar a qualidade de um modelo.

Previsão

Modelos de **aprendizado de máquina (ML)** são **treinados** para fazer previsões. A previsão produzida por um modelo de aprendizado de máquina sugere o que os **dados** representam ou o que pode ser útil para uma tarefa. Por exemplo, um desenvolvedor pode treinar um modelo para prever qual filme alguém pode querer assistir em seguida, com base em seus hábitos de visualização. O modelo irá gerar uma previsão após ser treinado com base nas escolhas de filmes de muitas pessoas. A principal função de um modelo de aprendizado de máquina é fazer previsões. Todos os modelos fazem previsões, mesmo que em alguns casos essas previsões não sejam óbvias para o usuário.

Rótulo

No **aprendizado supervisionado**, um **modelo** de **aprendizado de máquina (ML)** é **treinado** usando **dados** rotulados. Cada dado é anotado com um ou mais rótulos que fornecem informações sobre ele. Por exemplo, um modelo de aprendizado de máquina é projetado para identificar sons de pássaros. Cada som é identificado com o nome do pássaro que o emitiu. O modelo de aprendizado de máquina é treinado com os sons rotulados e pode **prever** o rótulo (nome do pássaro) de novos sons. Os dados são geralmente rotulados por pessoas para fornecer exemplos precisos para treinar modelos de aprendizado de máquina.

Treinamento

Modelos de aprendizado de máquina (ML) são treinados usando exemplos na forma de **dados** para encontrar padrões e fazer **previsões**. Durante o treinamento, os padrões são ajustados para melhorar as previsões. Por exemplo, um desenvolvedor pode criar um modelo para recomendar músicas. O modelo será treinado com base nas escolhas musicais de muitas pessoas para encontrar semelhanças entre o que diferentes indivíduos gostam de ouvir. Quanto mais diversificada for a seleção de músicas com a qual o modelo for treinado, melhor será a previsão da música recomendada. Existem muitas maneiras diferentes de treinar modelos de aprendizado de máquina usando diferentes tipos de dados. Um desenvolvedor escolherá entre os tipos de treinamento disponíveis dependendo do problema que está tentando resolver e dos dados disponíveis para resolvê-lo. A qualidade do treinamento depende em grande parte da qualidade dos dados utilizados.

Viés de dados

Viés de dados refere-se ao **viés** refletido nos **dados** utilizados para **treinar modelos de aprendizado de máquina (ML)**. O viés dos dados pode levar ao treinamento de modelos de ML para gerar **previsões** tendenciosas. Por exemplo, alguns modelos de reconhecimento facial são tendenciosos contra rostos de certos tons de pele, porque os modelos de aprendizado de máquina foram treinados usando principalmente imagens de rostos de um único tom de pele. Existem diversas fontes potenciais de viés nos dados. Isso inclui dados incompletos e dados que refletem **viés social**. Detectar vieses nos dados é importante para evitar que modelos de aprendizado de máquina gerem previsões tendenciosas.

Viés social

Viés social refere-se ao **viés** mantido por um grande grupo de pessoas ou pela sociedade em geral. Existem muitos tipos diferentes de preconceitos sociais, como preconceito racial, preconceito de gênero ou preconceito étnico. Um exemplo de preconceito de gênero é a ideia de que as mulheres são menos adequadas para carreiras de engenharia do que os homens. **Os dados** coletados de grandes grupos de pessoas podem refletir preconceitos sociais, resultando em **viés de dados**. Se dados que refletem viés social forem usados para **treinar modelos de aprendizado de máquina (ML)**, isso pode levar os **modelos** a gerar **previsões** enviesadas. No aprendizado de máquina (ML), é importante mitigar os vieses sociais refletidos nos **dados de treinamento**, para evitar resultados discriminatórios ou injustos.

Viés

Viés refere-se a uma preferência a favor ou contra algo. Por exemplo, um aluno pode preferir as aulas de inglês às aulas de matemática e dedicar mais tempo aos seus trabalhos de casa de inglês. Em outras palavras, eles têm um viés pela língua inglesa. Existem muitos tipos de viés, incluindo **viés social** e **viés de dados**. Desenvolvedores de **aprendizado de máquina (ML)** precisam pensar cuidadosamente se os **dados** que estão utilizando para **treinar modelos** de ML apresentam

viés ou não. Ser enviesado pode resultar em dar vantagem a uma pessoa, grupo ou conjunto de ideias ou crenças em comparação com outro.


Visão computacional

Visão computacional é o estudo de sistemas projetados para processar informações de imagens ou vídeos digitais. Exemplos de aplicações de visão computacional incluem reconhecimento facial, imagens médicas e videovigilância. Por exemplo, a visão computacional é usada no projeto de carros autônomos para detectar e evitar colisões com objetos. Na maioria das vezes, os sistemas de visão computacional utilizam **modelos de aprendizado de máquina** para identificar padrões em dados de imagem e vídeo. Os sistemas de visão computacional são úteis quando informações de imagens ou vídeos digitais podem ser usadas para resolver um problema.




Este recurso é licenciado pela [Raspberry Pi Foundation](https://www.raspberrypi.org/) sob uma Licença Pública Creative Commons Atribuição-Não Comercial-Sem Derivações 4.0 Internacional (CC BY-NC-ND 4.0). Para mais informações sobre este tipo de licença, acesse creativecommons.org/licenses/by-nc-nd/4.0/.

Experience AI



Este glossário foi criado pela Raspberry Pi Foundation como parte do nosso programa educacional, Experience AI. Saiba mais em www.experience-ai.org

Este recurso é licenciado pela Raspberry Pi Foundation sob uma Licença Pública Creative Commons Atribuição-NãoComercial-Sem Derivações 4.0 Internacional (CC BY-NC-ND 4.0). Para mais informações sobre este tipo de licença, acesse creativecommons.org/licenses/by-nc-nd/4.0.



Raspberry Pi
Foundation