


Raspberry Pi
Foundation

Experience AI

Glossário de
Termos de IA



Experience AI – Glossário de Termos

Este glossário explica os termos-chave da inteligência artificial (IA) e da aprendizagem automática (ML) utilizados nas [Lições do Programa Experience AI](#) e outros textos.

[Ir para o glossário](#)

Concebemos estas explicações principalmente para professores e educadores, a pensar no público jovem. Com este glossário, pretendemos ajudá-lo a reforçar a sua compreensão destes 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 a sua compreensão, ao passo que o seu uso inconsistente pode levar a conceções alternativas (equivocos) que podem interferir na aprendizagem dos alunos. Pode ler mais sobre este tópico na [nossa Leitura Rápida de Pedagogia sobre conceções alternativas](#). Enquanto professor, o uso regular e consistente de vocabulário técnico preciso pode apoiar a compreensão conceitual dos alunos.

Usámos a teoria das “ondas semânticas” para nos ajudar a escrever as explicações. Cada explicação segue a mesma estrutura de três partes: a primeira parte é uma explicação mais abstrata do termo, a segunda parte decompõe o significado do termo usando um exemplo comum e a terceira parte volta a compor o que foi explicado no exemplo em termos mais abstratos para fazer uma nova ligação ao vocabulário. Pode saber mais na [nossa Leitura Rápida de Pedagogia sobre ondas semânticas](#).

Esta é a versão 1 do glossário. Este glossário será aumentado, revisto e atualizado com a evolução das Lições do Programa Experience AI.

Índice

[Aprendizagem automática \(ML\)](#)
[Aprendizagem não supervisionada](#)
[Aprendizagem por reforço](#)
[Aprendizagem supervisionada](#)
[Árvore de decisão da ML](#)
[Baseado em regras](#)
[Característica da ML](#)
[Cartão de modelo de ML](#)
[Ciclo de vida do projeto de IA](#)
[Classe de ML](#)
[Classificação da ML](#)
[Confiança da ML](#)
[Dados de teste de ML](#)
[Dados de treino da ML](#)
[Dados](#)
[Depuração de dados](#)
[Exatidão da ML](#)
[Explicabilidade da ML](#)
[IA generativa](#)
[Inteligência artificial](#)
[Limiar de confiança da ML](#)
[Literacia em IA](#)
[Modelo de ML](#)
[Nó da árvore de decisão da ML](#)
[Orientado por dados](#)
[Preconceito social](#)
[Previsão da ML](#)
[Rótulo de ML](#)
[Tendência dos dados](#)
[Tendência](#)
[Treino da ML](#)
[Visão artificial](#)

Aprendizagem automática (ML)

A aprendizagem automática (ML ou "machine learning" em inglês) é uma abordagem usada para conceber e criar sistemas de **inteligência artificial (IA)**. Diz-se que a ML "aprende" usando exemplos na forma de **dados**, em vez de executar instruções passo a passo. Por outras palavras, as aplicações de ML são **orientadas por dados**. Por exemplo, uma aplicação de ML é usada para reconhecer discurso. Baseia-se em muitos exemplos de pessoas que falam com diferentes

sotaques e tons de voz. Outras aplicações de ML incluem a identificação de objetos em imagens ou jogos complexos. Cada aplicação de ML é concebida para resolver um problema específico.

Aprendizagem não supervisionada

A aprendizagem não supervisionada é uma abordagem usada para **treinar modelos de aprendizagem automática (ML)**. Os programadores de ML treinam modelos de aprendizagem não supervisionada para organizar os **dados** com base em semelhanças. Este processo resulta na descoberta de padrões ocultos nos dados. Um tipo de aprendizagem não supervisionada é o "clustering" ou agrupamento. Um exemplo de um problema de clustering é **prever** como os dados de saúde podem ser agrupados para ajudar a diagnosticar doenças. Esses grupos chamam-se "clusters", que não são conhecidos de antemão. O modelo de ML pode ser usado para prever se novos dados de saúde se enquadram num dos clusters. As abordagens de aprendizagem não supervisionada podem ser úteis na resolução de problemas em que as pessoas podem não saber o que procurar.

Aprendizagem por reforço

A aprendizagem por reforço é uma abordagem usada para **treinar modelos de aprendizagem automática (ML)**. Esta abordagem é utilizada para resolver problemas com um objetivo claro, em que recompensas e penalizações são utilizadas para atingir esse objetivo. As abordagens de aprendizagem por reforço são usadas na conceção de carros autónomos ou para jogar jogos complicados. Por exemplo, um modelo de aprendizagem por reforço poderá ser usado para conceber uma aplicação para jogar xadrez. O modelo é treinado para **prever** as jogadas que maximizam as recompensas e minimizam as penalizações com vista à vitória. As abordagens de aprendizagem por reforço usam recompensas e penalizações para identificar estratégias que atinjam um objetivo definido.

Aprendizagem supervisionada

A aprendizagem supervisionada é uma abordagem usada para **treinar modelos de aprendizagem automática (ML)**. As abordagens de aprendizagem supervisionada usam grandes quantidades de **dados rotulados** por pessoas com informações relevantes. Um tipo de aprendizagem supervisionada é a **classificação**. Um exemplo de um problema de classificação é a identificação de tigres na natureza. Os dados consistem em muitas imagens, sendo que aquelas que contêm tigres são rotuladas como tal.

O modelo de ML é treinado com as imagens rotuladas e **prevê** se há um tigre nessas imagens. O facto de ter imagens rotuladas corretamente permite ao programador saber até que ponto as previsões do modelo são **exatas** e adaptar o treino do modelo. Depois disso, o modelo de ML pode ser usado para prever se existe um tigre em imagens completamente novas. As abordagens de aprendizagem supervisionada dependem de dados suficientes rotulados corretamente para produzir previsões exatas.

Árvore de decisão da ML

Uma árvore de decisão da **aprendizagem automática (ML)** é um tipo de **modelo** de ML. Os programadores de ML usam árvores de decisão para estruturar um conjunto de condições com base nas quais se pode fazer uma **previsão**. As condições derivam de **características** nos **dados**. Por exemplo, uma árvore de decisão pode ser usada para criar um sistema de recomendação de filmes. O modelo da árvore de decisão é **treinado** usando as preferências de filmes de muitas pessoas. Durante o treino, as condições são geradas com base em características como o tipo de filme, a duração ou o ator ou atriz principal. O modelo de ML gera uma previsão do próximo filme que alguém poderá gostar de ver, em função da concordância das suas preferências com as condições do modelo. A estrutura das árvores de decisão da ML é gerada com base em grandes quantidades de dados e pode mudar se for treinada novamente com dados diferentes.

Baseado em regras

Trata-se de uma forma de conceber sistemas usando um conjunto de regras predefinidas. Por exemplo, um programa do jogo do galo (círculos e cruzes) é concebido usando regras sobre as jogadas a fazer para tentar ganhar o jogo. As regras são definidas por humanos que geralmente são especialistas no domínio do problema a resolver. Os sistemas de **inteligência artificial (IA)** criados com uma abordagem baseada em regras também são conhecidos como a "boa e velha IA". Os sistemas baseados em regras contrastam com os sistemas **orientados por dados** em que os **dados** são usados como exemplos de como resolver o problema. Os sistemas baseados em regras são úteis para resolver problemas quando é possível produzir e seguir regras que abrangem a maioria das situações.

Característica da ML

Na **aprendizagem automática (ML)**, os **dados** têm características associadas. Por exemplo, um conjunto de dados musicais pode ter características como o tempo, o tom, a energia ou o género. Alguns **modelos** de ML são **treinados** com recurso a características para encontrar semelhanças nos dados. Outros **preveem** novas características nos dados que as pessoas não veem com facilidade. Escolher quais as características a usar ao treinar um modelo de ML pode fazer a diferença no desempenho do modelo.

Cartão de modelo de ML

Um cartão de modelo de **aprendizagem automática (ML)** é uma forma de documentar informações essenciais sobre **modelos** de ML de uma forma estruturada. Os cartões de modelos de ML são escritos por programadores de ML, tanto para especialistas como não especialistas. Por exemplo, uma aplicação de ML é desenvolvida para traduzir diferentes idiomas, como do árabe para o francês e vice-versa. Um cartão de modelo inclui informações sobre a **exatidão** da tradução do modelo, bem como o desempenho do modelo em relação a jargões, gírias e dialetos. Outras informações do cartão de modelo poderão incluir o tipo de modelo de ML, diferentes indicadores de desempenho e até mesmo a **tendência** conhecida. Os cartões de modelo são criados durante a

etapa da explicação do **ciclo de vida do projeto de IA** para expor informações sobre as capacidades e limitações do modelo, de uma forma que seja fácil de entender.

Ciclo de vida do projeto de IA

O ciclo de vida do projeto de **inteligência artificial (IA)** refere-se às diferentes etapas que podem ser necessárias para conceber e criar um **modelo de aprendizagem automática (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 ML é concebido para gerar novas playlists de músicas. Um programador de ML pode primeiro considerar que tipo de playlist deseja criar. Em seguida, pode recolher e preparar dados de músicas. O modelo de ML é treinado e testado com os dados de músicas. O modelo de ML é avaliado para ver se funciona conforme o esperado. Por fim, o modelo de ML é explicado para que outros possam utilizá-lo. Normalmente, as etapas do ciclo de vida do projeto de IA são usadas iterativamente, e não uma após a outra. O ciclo de vida do projeto de IA é uma série de etapas iterativas usadas para criar e melhorar um modelo de ML.

Classe de ML

Para **treinar modelos de classificação**, os programadores de **aprendizagem automática (ML)** organizam os **dados** em grupos predefinidos que se chamam classes. As classes são definidas antecipadamente com base naquilo que as pessoas consideram ser útil para agrupar as coisas. Imagine uma aplicação de ML desenvolvida para identificar frutas num supermercado. Os dados podem ser organizados em classes de maçãs, bananas, laranjas, mirtilos, etc. Uma classe é um grupo de coisas que os modelos de classificação usam para identificar semelhanças nos dados.

Classificação da ML

A classificação refere-se à tarefa de atribuir coisas em grupos predefinidos que se chamam **classes**. As classes são definidas antecipadamente com base naquilo que as pessoas consideram ser útil para agrupar as coisas. Um exemplo de problema de classificação é a análise de sentimento de avaliações de músicas. Um **modelo** de classificação de **aprendizagem automática (ML)** é **treinado** com avaliações **rotuladas** por pessoas como "positivas" ou "negativas". Após o treino, o modelo de ML 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 classes. Uma abordagem de classificação é útil para resolver problemas quando a resposta se enquadra em grupos predefinidos.

Confiança da ML

A confiança refere-se ao grau de certeza de uma coisa. Na **aprendizagem automática (ML)**, a confiança é uma forma de medir a certeza de uma **previsão**. Por exemplo, um **modelo de classificação** é concebido para prever se vai chover amanhã. O modelo prevê com 90% de confiança de que haverá chuva amanhã. Ou seja, há 90% de certeza de que amanhã vai chover. Usar a confiança para medir a certeza das previsões ajuda a avaliar a qualidade de um modelo de ML.

Dados de teste de ML

Na **aprendizagem automática (ML)**, os dados de teste referem-se aos **dados** utilizados para testar e avaliar **modelos** de ML **treinados**. Por exemplo, um modelo de ML é treinado para **prever** o diagnóstico de uma condição médica. Antes de ser utilizado em situações da realidade, o modelo é testado e avaliado utilizando dados de teste. Os dados de teste estão separados dos **dados de treino** com os quais um modelo de ML é treinado. Os dados de teste são usados para medir o desempenho de um modelo de ML com exemplos além dos dados de treino.

Dados de treino da ML

Na **aprendizagem automática (ML)**, os dados de treino referem-se aos exemplos sob a forma de **dados** utilizados para **treinar modelos** de ML. Os programadores de ML criam modelos para descobrir padrões nos dados de treino, que podem ser usados para gerar **previsões** sobre novos dados. Por exemplo, um programador de ML cria uma aplicação de reconhecimento de voz. Os dados de treino podem incluir muitos exemplos de pessoas a falar, com diferentes sotaques ou tons de voz. Quanto mais os dados de treino representarem a realidade, maior a probabilidade de o desempenho do modelo ser melhor.

Dados

Os dados referem-se a valores, medições, factos ou observações numa forma adequada a ser processada por programas de computador. Há muitos tipos de dados, tais como texto, imagem ou som. Um exemplo de dados de texto são as mensagens que as pessoas trocam com amigos em dispositivos digitais. Na **aprendizagem automática (ML)**, os dados representam os exemplos com os quais os **modelos** de ML são **treinados**. Recolher, **limpar** e estruturar grandes quantidades de dados são etapas essenciais da conceção de modelos de ML.

Depuração de dados

A depuração de dados é um passo na preparação dos **dados** utilizados para **treinar um modelo de aprendizagem automática (ML)**. A depuração de dados envolve identificar e corrigir erros nos dados. Por exemplo, corrigir erros de digitação ou remover duplicados em dados de texto são duas tarefas simples da depuração de dados. Na maioria das vezes, os dados ficam desorganizados e exigem uma depuração mais complexa antes de serem usados para treinar modelos de ML. Há muitas maneiras de depurar dados, dependendo do problema e do tipo de dados. Usar dados depurados é essencial para criar modelos de ML **exatos**.

Exatidão da ML

A exatidão refere-se ao grau de correção de algo. Na **aprendizagem automática (ML)**, a exatidão é uma forma de medir a frequência com que um **modelo** de ML faz uma **previsão** correta. Por exemplo, um modelo de **classificação** é concebido para classificar maçãs. Entre 100 imagens de maçãs, 90 são classificadas corretamente. A exatidão da classificação do modelo é de 90%. A exatidão é uma forma de avaliar modelos de ML. Na maioria das vezes, a exatidão é usada juntamente com outras medições para avaliar a qualidade de um modelo.

Explicabilidade da ML

A explicabilidade refere-se ao ponto até ao qual algo pode ser compreendido. Na **aprendizagem automática (ML)**, a explicabilidade ajuda as pessoas a entender como é que uma **previsão** foi produzida. Por exemplo, os **modelos da árvore de decisão da ML** são explicáveis porque os **nós** podem ser analisados de uma forma que as pessoas possam entender. A maioria dos modelos de ML não são totalmente explicáveis e alguns são mais explicáveis do que outros. Aumentar a explicabilidade de um modelo pode ajudar a resolver problemas e a combater a **tendência**.

IA generativa

A IA generativa é um tipo de **inteligência artificial (IA)** concebida para gerar conteúdo, como texto, imagens ou som. Há muitas aplicações que usam IA generativa, incluindo a produção de arte ou música ou a geração de texto para chatbots. Por exemplo, aplicações de arte de IA generativa podem gerar uma imagem com base num pedido, como, por exemplo, "faça-me uma imagem de um dragão a ler um livro". A arte de IA generativa é criada usando **modelos de aprendizagem automática treinados** com milhões de imagens de arte existentes. As imagens resultantes poderão replicar o estilo de um artista, sem que o artista original saiba ou aprove. As aplicações de IA generativa estão a tornar-se cada vez mais comuns e, muitas vezes, não se consegue perceber que existe IA generativa por trás.

Inteligência artificial

A inteligência artificial (IA) é a conceção e o estudo de sistemas que parecem imitar um comportamento inteligente. Algumas aplicações de IA são baseadas em regras. As aplicações de IA são agora criadas, com mais frequência, através do recurso à **aprendizagem automática**, que supostamente "aprende" com exemplos na forma de **dados**. Por exemplo, algumas aplicações de IA são desenvolvidas para responder a perguntas ou para ajudar a diagnosticar doenças. Outras aplicações de IA podem ser desenvolvidas para fins prejudiciais, como a divulgação de notícias falsas. As aplicações de IA não pensam. As aplicações de IA são desenvolvidas para realizar tarefas de uma forma que parece inteligente.

Limiar de confiança da ML

O limiar de confiança refere-se a um valor definido como um nível de aceitação das **previsões** de um **modelo de aprendizagem automática (ML)**. O limiar de confiança é escolhido pelo programador de ML ao conceber o modelo de ML. 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 limiar de confiança for definido como 60%, essa previsão será considerada imprecisa. Por outras palavras, a menos que a confiança da previsão seja de 60% ou superior, não será aceite como **exata**. 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 musicais. A escolha do valor limite determina qual é o nível aceitável de confiança na previsão.

Literacia em IA

A literacia em IA é um conjunto de competências e formas de pensar que permite às pessoas interagir de forma significativa com aplicações de **inteligência artificial (IA)**, bem como em situações em que as aplicações de IA são utilizadas à sua volta. Essas competências incluem compreender a IA, estar envolvido no desenvolvimento de sistemas de IA e ter opiniões informadas sobre as formas como os sistemas de IA são utilizados no mundo. Por exemplo, uma pessoa usa a literacia em IA quando avalia a exatidão das informações fornecidas por uma aplicação chatbot de IA. Além de diferentes formas de envolvimento com aplicações de IA, a literacia em IA inclui o potencial das pessoas para participarem ativamente na decisão de como os sistemas de IA podem ser usados à sua volta.

Modelo de ML

Um modelo de **aprendizagem automática (ML)** é usado por uma aplicação de ML para realizar uma tarefa ou resolver um problema. O modelo de ML é uma representação do problema a resolver. Os programadores de ML usam grandes quantidades de **dados** representativos de um problema específico de modo a **treinar** um modelo para detetar padrões. O resultado do treino é um modelo, que é usado para fazer **previsões** sobre novos dados no mesmo contexto. Por exemplo, os carros autónomos são construídos com recurso a modelos de ML para preverem quando devem parar. Os modelos são treinados usando milhões de exemplos de situações em que os carros têm de parar. Há muitos tipos de modelos, que usam diferentes tipos de dados e diferentes formas de treinar os modelos. Todos os modelos de ML são treinados para detetar padrões nos **dados de treino** de modo a fazerem previsões sobre novos dados.

Nó da árvore de decisão da ML

Uma **árvore de decisão da aprendizagem automática (ML)** é composta por nós. Os nós são vinculados para formar uma estrutura com base na qual se pode gerar uma **previsão**. Há dois tipos de nós: nós de decisão e nós de folha. Por exemplo, considere uma árvore de decisão criada para prever os tipos de estrelas do nosso sistema solar. Os nós de decisão representam **características de dados**, como a temperatura, o raio, a cor ou o brilho das estrelas. Os nós de folha representam

os tipos de estrelas na forma de **rótulos** de previsão, como "anã vermelha", "anã branca" ou "anã castanha". Os nós da árvore de decisão formam a estrutura necessária para que um **modelo** de ML gere uma previsão.

Orientado por dados

Orientado por dados é uma forma de conceber sistemas usando **dados** em vez de instruções passo a passo. Por exemplo, é difícil saber o que causa certas doenças, mas há muitos dados de exemplos. Portanto, indivíduos que concebem os sistemas utilizam os dados médicos das pessoas afetadas pela doença para diagnosticá-la. Os sistemas orientados por dados contrastam com os sistemas **baseados em regras**. Os sistemas orientados por dados são adequados para resolver problemas quando é difícil produzir regras que abranjam todas as situações. Em vez disso, é possível recolher exemplos suficientes para dar forma a uma solução.

Preconceito social

O preconceito social refere-se à **tendência** de um grande grupo de pessoas ou da sociedade em geral. Há muitos tipos diferentes de preconceitos sociais, como o preconceito racial, o preconceito de género ou o preconceito étnico. Um exemplo de preconceito de género é a ideia de que as mulheres são menos adequadas às carreiras de engenharia do que os homens. Os **dados** recolhidos de grandes grupos de pessoas poderão refletir preconceitos sociais, resultando numa **tendência dos dados**. Se os dados que refletem preconceitos sociais são usados para **treinar modelos de aprendizagem automática (ML)**, isso pode levar a que os modelos gerem **previsões** tendenciosas. Na ML, é importante mitigar os preconceitos sociais refletidos nos **dados de treino**, para evitar resultados discriminatórios ou injustos.

Previsão da ML

Os **modelos de aprendizagem automática (ML)** são **treinados** para fazer previsões. A previsão produzida por um modelo de ML sugere aquilo que os **dados** representam ou aquilo que pode ser útil para uma tarefa. Por exemplo, um programador de ML pode treinar um modelo para prever o próximo filme que alguém poderá querer ver, com base nos seus hábitos de visualização. O modelo gera uma previsão após ser treinado com as escolhas de filmes de muitas pessoas. A principal função de um modelo de ML é fazer previsões. Todos os modelos de ML fazem previsões, mesmo que, nalguns casos, essas previsões não sejam óbvias para o utilizador.

Rótulo de ML

Na **aprendizagem supervisionada**, um **modelo de aprendizagem automática (ML)** é **treinado** utilizando **dados** rotulados. Cada dado é anotado com um ou mais rótulos que fornecem informações sobre esses dados. Por exemplo, um modelo de ML é concebido para identificar sons de pássaros. Cada som é rotulado com o nome do pássaro que emitiu o som. O modelo de ML 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 exatos para treinar modelos de ML.

Tendência dos dados

A tendência dos dados refere-se à **tendência** refletida nos **dados** usados para **treinar modelos de aprendizagem automática (ML)**. A tendência (ou viés) dos dados pode fazer com que os modelos de ML sejam treinados para gerar **previsões** tendenciosas. Por exemplo, alguns modelos de reconhecimento facial são tendenciosos contra rostos de determinados tons de pele, porque os modelos de ML foram treinados principalmente com imagens de rostos de um tom de pele. Há várias potenciais fontes de tendência dos dados. Essas fontes incluem dados incompletos e dados que refletem **preconceitos sociais**. É importante detectar uma tendência ou viés de dados para evitar que modelos de ML gerem previsões tendenciosas.

Tendência

A tendência refere-se a uma preferência a favor de ou contra algo. Por exemplo, um aluno pode preferir aulas de inglês a aulas de matemática e dedicar mais tempo aos trabalhos de casa de inglês. Por outras palavras, tem uma tendência para a disciplina de inglês. Há muitos tipos de tendências, incluindo o **preconceito social** e a **tendência dos dados**. Os programadores de **aprendizagem automática (ML)** têm de pensar cuidadosamente se os **dados** que utilizam para **treinar modelos de ML** são ou não tendenciosos. Ser tendencioso pode resultar em dar vantagem a uma pessoa, grupo ou conjunto de ideias ou crenças em detrimento de outro.

Treino da ML

Os **modelos de aprendizagem automática (ML)** são treinados com exemplos na forma de **dados** para encontrar padrões e fazer **previsões**. Durante o treino, os padrões são ajustados para melhorar as previsões. Por exemplo, um programador de ML pode criar um modelo para recomendar músicas. O modelo de ML é treinado com as escolhas musicais de muitas pessoas para encontrar semelhanças naquilo que diferentes pessoas gostam de ouvir. Quanto mais diversas as opções de músicas com que o modelo é treinado, maior a probabilidade de a previsão de músicas recomendadas ser melhor. Há muitas maneiras de treinar modelos de ML, usando diferentes tipos de dados. Um programador escolhe entre os tipos de treino disponíveis, dependendo do problema que tenta resolver e dos dados disponíveis para o resolver. A qualidade do treino depende, em grande parte, da qualidade dos dados utilizados.


Visão artificial

A visão artificial é o estudo de sistemas concebidos para processar informações de imagens digitais ou vídeos. Exemplos de aplicações de visão artificial incluem o reconhecimento facial, a imagiologia médica e a videovigilância. Por exemplo, a visão artificial é usada na conceção de carros autónomos para detetar e evitar colisões com objetos. Na maioria das vezes, os sistemas de visão artificial usam **modelos de aprendizagem automática** para identificar padrões nos dados de imagens e vídeos. Os sistemas de visão artificial são úteis quando as informações de imagens digitais ou vídeos podem ser usadas para resolver um problema.




Este recurso é licenciado pela [Raspberry Pi Foundation](https://www.raspberrypi.org/) através de uma Licença Pública Internacional Creative Commons Attribution-NonCommercial-NoDerivatives 4.0 (CC BY-NC-ND 4.0). Para mais informações sobre esta licença, consulte [creativecommons.org/licenses/by-nc-nd/4.0.](https://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 através de uma Licença Pública Internacional Creative Commons Attribution-NonCommercial-NoDerivatives 4.0 (CC BY-NC-ND 4.0). Para mais informações sobre esta licença, consulte creativecommons.org/licenses/by-nc-nd/4.0.



Raspberry Pi
Foundation