




# Manual Desencadeado da Máquina Ensinable

Um Tutorial Abrangente



M{AI}L

# Índice


**Manual Desencadeado da Teachable Machine ..... 1**
**Introdução: O futuro da aprendizagem nas suas mãos ..... 5**
**Módulo 1: Fundamentos de IA e Aprendizagem Automática para a Sala de Aula ..... 7**
1.1 Desmistificando a Inteligência Artificial (IA) ..... 8
1.1.1 O que é IA? Conceitos-chave explicados de forma simples ..... 8
1.1.2 Um Vislumbre da História da IA: Da Curiosidade à Realidade ..... 10
1.2 Compreender a Aprendizagem Automática (AA): Como os Computadores Aprendem ..... 11
1.2.1 O que é ML? Conceitos básicos e exemplos do dia a dia ..... 11
1.2.2 O processo de aprendizagem em ML: como "treinamos" uma máquina ..... 14
1.2.3 Tipos de Aprendizagem Automática: diferentes abordagens à aprendizagem ..... 15
1.2.4 A relação entre IA e ML: uma parceria para a inteligência ..... 16
1.3 A importância da literacia em IA e ML para educadores ..... 17
1.3.1 Preparar os alunos para o futuro ..... 17
1.3.2 Avaliar e selecionar ferramentas de IA ..... 19
1.3.3 Integração da IA no currículo ..... 20
1.4 IA como ferramenta pedagógica: benefícios para professores e alunos ..... 21
1.4.1 IA para aprendizagem personalizada: adaptar a educação às necessidades individuais ..... 21
1.4.2 IA para melhorar o ensino: capacitar os educadores com ferramentas inteligentes ..... 23
1.4.3 IA para acessibilidade e inclusão ..... 24
1.4.4 IA para Avaliação e Feedback ..... 25
1.4.5 IA para a criação de conteúdos educativos ..... 26
1.4.6 IA para desenvolvimento profissional ..... 27
1.5 Para além das disciplinas STEM: IA noutras disciplinas ..... 27
**Módulo 2: Introdução à Máquina Aprendível: O Seu Laboratório de Criação de IA ..... 30**
2.1 Explorando a Máquina Aprendível: IA para Todos ..... 31
2.1.1 Principais Funcionalidades e Funcionalidades ..... 31
2.1.2 Como a Máquina Aprendível Simplifica o Aprendizado Automático ..... 32
2.1.3 Por que usar a Máquina Aprendível na educação? Principais benefícios ..... 33
2.2 Preparar o seu ambiente: acesso e tipos de projetos ..... 36
2.2.1 Acesso à Máquina Aprendível: Requisitos e Início ..... 36
2.2.2 Compreender os tipos de projeto: imagem, áudio e pose ..... 38
2.2.3 Navegar pelo Ambiente de Trabalho da Máquina Aprendível ..... 40
**Módulo 3: Criação de Projetos de Imagem ..... 46**
3.1 Planeamento de projetos: Definir a sua IA baseada em imagens ..... 47
3.1.1 Identificar aplicações em sala de aula para reconhecimento de imagens ..... 47
3.1.2 Escolha de objetos ou conceitos adequados para classificação ..... 48
3.1.3 Definição dos critérios de sucesso do projeto ..... 49

3.2 Recolha e preparação de dados: Construir o seu conjunto de dados ..... 51
3.2.1 Recolha de dados de imagens: fontes e métodos ..... 51
3.2.2 Criação de Classes de Imagem: Definindo Categorias para o Seu Modelo ..... 55
3.2.3 Aumento de Dados: Melhorar o Seu Conjunto de Dados ..... 57
3.2.4 Prepare os Seus Dados para a Máquina Aprendível ..... 58
3.3 Treino e Avaliação de Modelos: Dar Vida à Sua IA ..... 60
3.3.1 Treinar o seu modelo de imagem: passo a passo ..... 60
3.3.2 Avaliação do Desempenho do Modelo: Compreensão da Precisão e Métricas ..... 65
3.3.3 Resolução de problemas e melhoria do seu modelo ..... 66
3.4 Aplicações na Sala de Aula: IA de Imagem em Ação ..... 69
3.4.1 Atividades de aprendizagem interativas com reconhecimento de imagem ..... 69
3.4.2 Integração da IA de Imagem em Disciplinas Específicas ..... 70
3.4.3 Estratégias de avaliação utilizando projetos de IA baseados em imagem ..... 72
**Módulo 4: Criação de Projetos de Áudio ..... 75**
4.1 Planeamento de projetos: Definir a sua IA baseada em áudio ..... 76
4.1.1 Identificação de aplicações em sala de aula para reconhecimento áudio ..... 76
4.1.2 Escolha de sons ou padrões de voz adequados para classificação ..... 77
4.1.3 Definição dos critérios de sucesso do projeto ..... 79
4.2 Recolha e preparação de dados: Construa o seu conjunto de dados áudio ..... 81
4.2.1 Recolha de dados áudio: fontes e métodos ..... 81
4.2.2 Criação de Classes de Áudio: Definição de Categorias para o Seu Modelo ..... 83
4.2.3 Aumento de Dados de Áudio: Melhorar o Seu Conjunto de Dados ..... 85
4.2.4 Prepare os seus dados para o Teachable Machine ..... 86
4.3 Treino e Avaliação de Modelos: Dar Vida à Sua IA de Áudio ..... 88
4.3.1 Treinar o seu modelo áudio: passo a passo ..... 88
4.3.2 Avaliação do Desempenho do Modelo: Compreensão da Precisão e Métricas ..... 92
4.3.3 Resolução de problemas e melhoria do seu modelo ..... 93
4.4 Aplicações na Sala de Aula: IA de Áudio em Ação ..... 95
4.4.1 Atividades de aprendizagem interativas com reconhecimento áudio ..... 95
4.4.2 Integração da IA de Áudio em Aulas Específicas por Disciplina ..... 97
4.4.3 Estratégias de avaliação utilizando projetos de IA baseados em áudio ..... 99
**Módulo 5: Criação de Projetos de Pose ..... 102**
5.1 Planeamento de projetos: Defina a sua IA baseada em poses ..... 103
5.1.1 Identificação de aplicações em sala de aula para reconhecimento de poses ..... 103
5.1.2 Escolha de Posturas ou Movimentos Adequados para Classificação ..... 104
5.1.3 Definição dos critérios de sucesso do projeto ..... 105
5.2 Recolha e preparação de dados: Construir o seu conjunto de dados para poses ..... 107
5.2.1 Recolha de Dados de Pose: Fontes e Métodos ..... 107
5.2.2 Criação de Classes de Pose: Definindo Categorias para o Seu Modelo ..... 110
5.2.3 Aumenta os teus dados de pose: mais exemplos, melhor aprendizagem ..... 111
5.2.4 Prepare os Seus Dados para a Máquina Aprendível ..... 112

5.3 Treino e Avaliação de Modelos: Dar Vida à Sua IA de Poses ..... 114
5.3.1 Treinar o seu modelo de pose: passo a passo ..... 114
5.3.2 Avaliação do Desempenho do Modelo: Compreensão da Precisão e das Métricas ..... 118
5.3.3 Resolução de problemas e melhoria do seu modelo ..... 120
5.4 Aplicações na sala de aula: colocar a IA em ação ..... 121
5.4.1 Atividades de aprendizagem interativas com reconhecimento de poses ..... 121
5.4.2 Integração da Pose AI em Turmas Específicas por Disciplina ..... 123
5.4.3 Estratégias de avaliação utilizando projetos de IA baseados em pose ..... 125
**Módulo 6: Estratégias de integração na sala de aula: abordagens pedagógicas ..... 128**
6.1 Integre a Máquina Ensinable no seu planeamento de aulas ..... 129
6.2 Promoção da aprendizagem centrada no aluno com IA ..... 130
6.3 Considerações éticas e uso responsável da IA na sala de aula ..... 131
6.4 Enfrentar desafios comuns ..... 133
**Módulo 7: Recursos e Apoio: O Seu Guia para a Aprendizagem Contínua ..... 136**
7.1 Recursos Online para Máquina Aprendível ..... 137
7.2 Mergulho Profundo em IA e Aprendizagem Automática ..... 138
7.3 Apoio Contínuo e Atualizações ..... 138
7.4 Kits Práticos de Ferramentas de IA e Software Educativo para a Sala de Aula ..... 139
7.5 Quadros éticos globais e diretrizes políticas sobre IA ..... 140
7.6 Desenvolvimento de práticas sustentáveis e divulgação de projetos ..... 141
**Conclusão: Capacitar os futuros alunos com IA ..... 143**

# Introdução: O futuro da aprendizagem nas suas mãos

Bem-vindo ao manual M{AI}L – Aprendizagem Automática e Inteligência Artificial para a Educação. Num mundo em rápida mudança, a Inteligência Artificial (IA) já não é um conceito de ficção científica, mas uma realidade presente que influencia as nossas vidas diárias. Como educadores, o nosso papel é fundamental na preparação das novas gerações para este futuro. Este manual é uma ferramenta concebida para o ajudar, enquanto professor do ensino básico, a introduzir conceitos de IA e Aprendizagem Automática (ML) nas suas salas de aula de forma acessível, envolvente e relevante.

**O que vais encontrar neste manual?**

Aqui, vai mergulhar no mundo da IA e do ML através do Teachable Machine (Máquina Aprendível), uma ferramenta intuitiva baseada na web da Google que lhe permite criar modelos de aprendizagem automática sem necessidade de escrever qualquer código. Esta funcionalidade permiti-lhe:

- **Compreenda os fundamentos:** Vamos desmistificar o que são IA e ML com explicações claras e exemplos relevantes para o seu dia a dia.
- **Master Teachable Machine:** Irá aprender, passo a passo, como usar esta ferramenta para criar os seus próprios projetos de reconhecimento de imagens, áudio e poses.
- **Candidate-se na sala de aula:** Forneceremos ideias práticas e exemplos concretos para integrar estes projetos nas suas aulas de ciências e línguas, alinhando-as com o currículo e promovendo a aprendizagem ativa.
- **Resolver desafios:** Vamos abordar as dificuldades comuns que os professores enfrentam na integração da tecnologia, oferecendo soluções práticas baseadas nas experiências de outros educadores.

- **Incentive a aprendizagem ao seu próprio ritmo:** Verá como incentivar os seus alunos a criar os seus próprios exercícios e a explorar estes conceitos ao seu próprio ritmo, promovendo a sua autonomia e interesse.

**Porque é importante para si e para os seus alunos?**

A integração da IA na educação é essencial por várias razões principais, muitas das quais foram destacadas por outros professores, tais como:

- **Preparar-se para o futuro:** A IA está a transformar o mercado de trabalho, e os seus alunos vão precisar de competências para se adaptarem a estes novos ambientes e, potencialmente, seguir carreiras em áreas relacionadas com IA. Este manual prepara-o para ser um facilitador nessa jornada.
- **Desenvolvimento de competências-chave:** Aprender com IA promove o pensamento crítico, a resolução de problemas, a criatividade e a colaboração. Estas são competências essenciais para o século XXI.
- **Motivação e envolvimento:** A IA pode tornar a aprendizagem mais interativa e envolvente, especialmente para os "nativos digitais" que já estão habituados à tecnologia. A Máquina Ensinable, por ser tão prática, capta o interesse e a curiosidade dos alunos.
- **Redução da carga de trabalho:** Ao simplificar a criação de materiais e exercícios, a IA pode libertar tempo para que possa concentrar-se em inspirar e orientar os seus alunos.
- **Literacia em IA:** Este manual contribui para a sua própria 'literacia em IA', dando-lhe confiança e conhecimento para avaliar ferramentas, integrar conceitos no seu currículo e abordar as implicações éticas de forma responsável.

Com a M{AI}L, não está apenas a ensinar tecnologia; está a cultivar uma nova geração de pensadores críticos e criadores, capazes de navegar e contribuir para o mundo orientado pela tecnologia de forma informada e segura.

# Módulo 1: Fundamentos de IA e Aprendizagem Automática para a Sala de Aula

Neste módulo, vamos lançar as bases para compreender a Inteligência Artificial (IA) e o Machine Learning (ML). Não precisa de ser um especialista em tecnologia para compreender estes conceitos. O nosso objetivo é apresentá-los de forma clara, com exemplos simples relevantes para o seu dia a dia e, claro, para a sala de aula do ensino básico.

## 1.1 Desmistificando a Inteligência Artificial (IA)

A Inteligência Artificial (IA) emergiu como uma das tecnologias mais transformadoras do nosso tempo, transformando rapidamente indústrias, sociedades e até as nossas vidas quotidianas. Já não é um conceito futurista de ficção científica; A IA é uma realidade presente e a sua influência deverá crescer. É crucial que, enquanto educadores, compreendamos o que é IA para podermos guiar os nossos alunos a interagir com ela de forma informada e significativa.

### 1.1.1 O que é IA? Conceitos-chave explicados de forma simples

No seu cerne, a Inteligência Artificial é a **capacidade de um sistema informático processar informação, aprender com dados e realizar tarefas que normalmente requerem inteligência humana.** Estas tarefas incluem, mas não se limitam a, resolução de problemas, tomada de decisão, compreensão de linguagem e reconhecimento de padrões.

Vamos pensar na IA como um conjunto de ferramentas e técnicas que permitem aos computadores fazer coisas que, anteriormente, só os humanos podiam fazer, tais como:

- **Compreender e responder à linguagem natural:** Isto significa que os sistemas de IA podem processar e interpretar a linguagem humana. Pense em assistentes de voz como a Siri ou a Alexa, ou em ferramentas de tradução automática que permitem comunicar em diferentes línguas.
- **Reconheça padrões e faça previsões:** Os sistemas de IA podem analisar grandes quantidades de dados para identificar tendências, relações ou anomalias. Isto permite-lhes prever resultados futuros ou tomar decisões informadas. Por exemplo, um sistema de IA pode prever que filmes vai gostar com base no que já viu.

- **Adaptar-se a novas situações e aprender com a experiência:** Ao contrário dos programas tradicionais, que seguem instruções fixas, os sistemas de IA podem aprender e melhorar o seu desempenho ao longo do tempo. Isto torna-os muito mais flexíveis e capazes de se adaptar a novas situações. Por exemplo, um filtro de spam no seu email aprende a identificar quais os emails que são lixo com base nos exemplos que recebe diariamente.
- **Resolver problemas complexos e tomar decisões:** A IA pode lidar com problemas difíceis que são difíceis de resolver para humanos, e também pode automatizar processos de tomada de decisão. Exemplos incluem sistemas que ajudam médicos a diagnosticar doenças ou que gerem o trânsito numa cidade.

É importante lembrar que, quando falamos de "comportamento inteligente" na IA, não nos referimos necessariamente à replicação da consciência ou emoções humanas. A IA foca-se em máquinas que demonstram inteligência para tarefas específicas ou domínios problemáticos.

A IA está fundamentalmente enraizada na ciência da computação, utilizando:

- **Algoritmos:** Um conjunto de regras ou instruções que um computador segue para realizar uma tarefa.
- **Dados:** a informação que o sistema processa e da qual aprende.
- **Poder computacional:** a capacidade dos computadores de processar e manipular informação.

A IA é um campo de investigação e desenvolvimento contínuos, e a nossa compreensão do tema continuará a evoluir. Isto significa que, enquanto educadores, devemos manter uma mentalidade proativa e adaptável, atualizando constantemente as nossas competências digitais para orientar eficazmente os alunos a serem utilizadores informados, críticos e responsáveis destas tecnologias em evolução.

### 1.1.2 Um Vislumbre da História da IA: Da Curiosidade à Realidade

Para compreender onde estamos no que toca à IA, é essencial olhar para onde começámos. A história da IA é uma jornada fascinante marcada por avanços e desafios, períodos de grande entusiasmo e outros de baixo investimento.

- **Os primórdios da IA (décadas de 1940 e 1950):** As sementes da IA foram semeadas com os primeiros computadores eletrónicos e a questão de saber se as máquinas podiam 'pensar'. O evento definidor foi o **Workshop** de **Dartmouth em 1956**, amplamente considerado o nascimento oficial da IA como campo formal de investigação. Nesta fase, os investigadores tentaram ensinar os computadores a raciocinar usando símbolos e regras lógicas.
- **A era do otimismo (anos 60):** Foi um período de grande entusiasmo em torno do processamento de linguagem natural e dos jogos de computador. Havia o sonho de máquinas que pudessem falar e brincar como humanos.
- **Os 'Invernos da IA' (anos 1970 e final dos anos 1980/início dos anos 1990):** A realidade colidiu com as expectativas. As limitações dos computadores e das abordagens de IA da época (IA simbólica) fizeram com que muitos projetos não cumprissem as suas promessas. Isto levou a uma redução de financiamento e de juros.
- **A ascensão dos sistemas especialistas (década de 1980):** A IA recuperou força com o desenvolvimento de 'sistemas especialistas', programas concebidos para imitar o conhecimento dos especialistas humanos em áreas específicas, como o diagnóstico médico.
- **A era da Aprendizagem Automática (anos 90 – presente):** Foi aqui que a IA realmente descolou. O foco mudou para o desenvolvimento de algoritmos que permitissem aos computadores aprender a partir de dados sem programação explícita. Os fatores-chave incluíam o aumento do poder de computação, a disponibilidade de grandes conjuntos de dados (graças à Internet) e avanços nos algoritmos.
- **A revolução da Aprendizagem profunda (décadas de 2010 – 2023):** Um subcampo da Aprendizagem Automática, a "Aprendizagem Profunda", que utiliza Redes Neurais

Artificiais de múltiplas camadas, alcançou resultados impressionantes em reconhecimento de imagem, fala e linguagem. Isto sustenta grande parte da IA que usamos hoje, desde assistentes virtuais a carros autónomos.

- **A Era Gerativa (2023 – Presente):** A IA torna-se "criativa". Grandes Modelos de Linguagem (LLMs), como o ChatGPT e o Gemini, permitem que qualquer pessoa interaja com IA através da linguagem natural, enquanto ferramentas como o Teachable Machine permitem aos utilizadores criar facilmente modelos de ML personalizados.

Hoje, a IA é uma força em rápido crescimento e omnipresente que está a transformar muitos aspetos das nossas vidas.

## 1.2 Compreender a Aprendizagem Automática (ML): Como os Computadores Aprendem

Aprendizagem Automática (ML), ou «Aprendizaje Automático» em espanhol, é um ramo muito entusiasmante da Inteligência Artificial (IA). Pense em ML como a forma como os computadores aprendem com a experiência, tal como nós, mas a partir de grandes quantidades de dados.

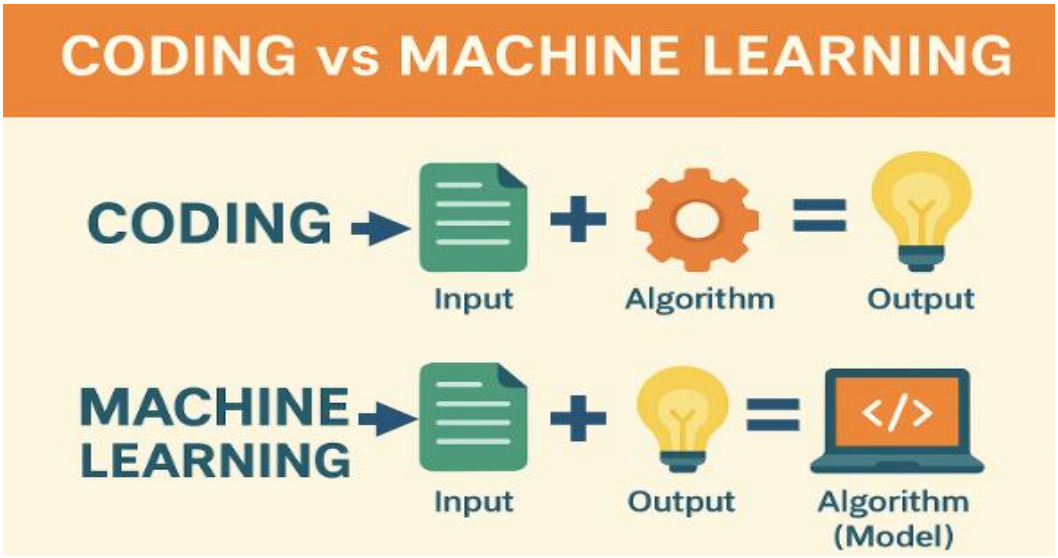
### 1.2.1 O que é ML? Conceitos básicos e exemplos do dia a dia

ML consiste em permitir que os computadores **aprendam a partir de dados, sem termos de especificar cada instrução individualmente**. É mais como ensinar um computador mostrando-lhe muitos exemplos; depois o computador identifica os padrões e aprende a fazer a tarefa por si próprio.

- **A diferença em relação à programação tradicional:** na programação clássica, dizemos ao computador exatamente o que fazer, passo a passo. Se algo muda, temos de reescrever as instruções. Com o ML, fornecemos ao computador uma enorme quantidade de exemplos (dados) e deixamos que ele descubra os padrões por si próprio. Isto permite que o sistema de ML se adapte sem necessidade de reprogramação explícita caso as coisas mudem.

- **O poder da adaptação:** Esta capacidade de aprender e adaptar-se é o que torna o ML tão poderoso. Permite aos computadores lidar com problemas complexos que seriam muito difíceis de resolver com programação tradicional.
- **Relevância para a educação:** A iniciativa de ML propõe introduzir conceitos de IA e ML numa fase inicial do ensino e correlacionar as atividades em sala de aula com as realidades tecnológicas dos alunos. Isto não só garante uma interação informada e significativa com estas ferramentas, como também ajuda a prevenir potenciais riscos relacionados com elas.

Em resumo, o Machine Learning pode ser definido como: **"Um tipo de IA que permite aos sistemas informáticos aprender a partir dos dados, identificar padrões, fazer previsões ou tomar decisões sem serem explicitamente programados. Este processo de aprendizagem significa que os modelos de Machine Learning melhoram à medida que são expostos a mais dados."**




💡 Dica para o professor

**A analogia do chef:** Explique aos alunos que a IA é como um chef. A programação tradicional é como seguir uma receita (instruções fixas, passo a passo). A aprendizagem automática é o paladar do chef: depois de provar 1.000 sopas, o chef aprende o que significa "salgado" ou "doce" e cria novas receitas sem precisar de um guia escrito.

Os elementos centrais do ML são:

- **Aprender com os dados:** Os algoritmos de ML aprendem examinando dados, identificando padrões e extraindo perceções úteis. Os dados são o 'combustível' que alimenta a ML.
- **Reconhecimento de padrões:** Estes algoritmos foram concebidos para encontrar ligações e relações ocultas nos dados. Imagine um computador a detetar tendências no desempenho dos alunos ou a identificar diferentes estilos de aprendizagem.
- **Previsão e tomada de decisão:** Os modelos de ML usam o que aprenderam para fazer previsões ou decisões quando confrontados com nova informação. Pense nas aplicações, como prever quais os alunos que podem precisar de apoio adicional.
- **Melhoria através da experiência:** o ML é um processo de melhoria contínua e aperfeiçoamento; os modelos melhoram à medida que analisam mais dados e ganham mais experiência.

**A importância dos dados na Aprendizagem Automática: o combustível para a aprendizagem**

Os dados são absolutamente cruciais em Aprendizagem Automática. Os algoritmos de Aprendizagem Automática aprendem a partir dos dados, e a qualidade e quantidade dos seus dados influenciam significativamente o desempenho dos modelos de Aprendizagem Automática.

- **Dados como material de treino:** Os modelos de ML são treinados com conjuntos de dados, que são coleções de dados usadas para ensinar o modelo a reconhecer padrões e fazer previsões. Pense nestes conjuntos de dados como o "material de treino" que ensina o sistema de ML ao que deve procurar.
- **A qualidade dos dados é essencial:** a precisão, completude e consistência dos dados são verdadeiramente importantes. Se os dados forem desorganizados ou tendenciosos, os resultados também serão desorganizados ou tendenciosos. É aqui que entra a literacia dos dados.

- **Quantidade e variedade de dados:** Os modelos de ML frequentemente precisam de uma grande quantidade de dados, e dados que abrangem uma vasta gama de exemplos, para aprender verdadeiramente e eficazmente. É uma boa ideia incentivar os alunos a recolher diferentes tipos de dados para os seus projetos de ML. Quanto mais diversificados forem os dados, melhor será o modelo a lidar com diferentes situações.

### 1.2.2 O processo de aprendizagem de ML: Como "treinamos" uma máquina

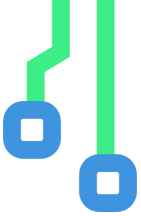
Em Aprendizagem Automática, "aprendizagem" não se refere a uma compreensão consciente como a dos seres humanos. É, antes, um programa de computador que melhora em algo ao olhar para muitos exemplos. É um processo de refinamento e melhoria, muito semelhante à forma como os alunos aprendem através da prática e do feedback.

O processo de aprendizagem de ML, simplificado, consiste em três etapas principais:

1. **Recolha de dados:** É aqui que o seu computador recolhe os exemplos dos quais irá aprender.
2. **Treino de modelo:** Esta é a própria fase de "aprendizagem", em que o computador analisa os dados para identificar padrões.
3. **Avaliação do modelo:** Nesta fase, verifica o quão bem o computador aprendeu. Testa o sistema para ver quão preciso é.

**Considerações-chave no processo de aprendizagem:**

- **Interação e refinamento:** Desenvolver modelos de ML é frequentemente um processo interativo. Pode precisar de ajustar e melhorar o seu modelo para obter os resultados desejados. Trata-se de experimentar e fazer ajustes para alcançar o melhor resultado. Isto é muito semelhante ao ensino, onde os professores ajustam constantemente os seus métodos e abordagens.
- **O papel do feedback:** Os algoritmos de ML usam feedback para aprender a partir dos dados. Na aprendizagem supervisionada (que vamos usar com a Teachable Machine), esse feedback provém dos dados rotulados que fornece. O computador aprende



comparando as suas previsões com as respostas corretas. Isto é semelhante à forma como os alunos aprendem com o feedback dos seus professores; o feedback é essencial para o crescimento e a melhoria.

- **Armadilhas comuns em Aprendizagem Automática e como as evitar:**
    - **Overfit:** Isto significa que o modelo aprende *dados de treino demasiado bem* e não consegue lidar com dados novos. É como um aluno que só memoriza exemplos específicos, mas não compreende verdadeiramente os conceitos subjacentes; o modelo torna-se demasiado especializado e não consegue generalizar para novas situações.
    - **Subajuste:** Por outro lado, isto significa que o modelo não aprende suficientemente bem os dados de treino. É como um estudante que não compreende a ideia básica; o modelo é demasiado simplista para captar a complexidade dos dados.
    - **Equívoco sobre objetividade:** A IA nem sempre é objetiva ou neutra só porque é uma máquina. A IA é um reflexo direto dos dados que consome. Se os dados de treino forem enviesados ou incompletos, a IA irá repetir e amplificar esses preconceitos. É 'influenciada' pelos dados fornecidos pelos humanos.
- **Aprendizagem contínua:** Os modelos de ML por vezes precisam de ser atualizados ou retreinados para continuarem a funcionar bem. O mundo está em constante mudança e os sistemas de ML precisam de se adaptar. Isto é semelhante ao conceito de aprendizagem ao longo da vida: a aprendizagem é um processo contínuo.
- **Processo iterativo e experimental:** O desenvolvimento de modelos de ML é frequentemente um processo experimental. Envolve explorar diferentes abordagens e encontrar o que funciona melhor. Isto incentiva um espírito de investigação, curiosidade e vontade de experimentar coisas novas.

### 1.2.3 Tipos de Aprendizagem Automática: diferentes abordagens à aprendizagem

Existem diferentes formas pelas quais os sistemas de Aprendizagem Automática podem aprender. As mais relevantes para o nosso contexto são:

- **Aprendizagem supervisionada: Aprender com um professor**
  - **A ideia central:** Na aprendizagem supervisionada, o computador aprende a partir de exemplos em que lhe são dadas as "respostas". É como um professor que fornece uma folha de exercícios com um modelo. O computador aprende a associar uma entrada à sua saída correta.
  - **Exemplo da Teachable Machine:** Quando treina um modelo de imagem para reconhecer "cães" e "gatos", fornece muitas fotos de cães *rotulados como* "*cão*" e muitas fotos de gatos *rotulados como* "*gato*". O modelo aprende com estes pares "pergunta-resposta". O Teachable Machine baseia-se principalmente neste tipo de aprendizagem.
- **Aprendizagem não supervisionada: Aprendizagem através da exploração**
  - **A ideia central:** Aqui, o computador aprende com exemplos em que *não* lhe dás as "respostas". A sua tarefa é encontrar padrões e ligações por si próprio, explorando a informação. É mais uma descoberta.
  - **Exemplo:** Imagine dar ao computador uma coleção de documentos de texto e pedir-lhe para encontrar temas comuns ou agrupar documentos semelhantes, sem lhe informar os temas antecipadamente. Isto não é tão simples para criar projetos no Teachable Machine, mas é um conceito importante em ML.
- **Aprendizagem por reforço: Aprender fazendo**
  - **A ideia central:** Na aprendizagem por reforço, o computador aprende interagindo com o seu ambiente e recebendo "recompensas" ou "penalizações" pelas suas ações. É uma aprendizagem de "tentativa e erro", semelhante ao treino de um cão: o cão aprende associando ações a recompensas ou punições.
  - **Exemplo:** Um carro autónomo aprende a conduzir recebendo "recompensas" por permanecer na sua faixa e "penalizações" por desviar ou estar envolvido num acidente. Este tipo de aprendizagem é mais complexo e não é diretamente aplicável na Teachable Machine.

### 1.2.4 A relação entre IA e ML: uma parceria para a inteligência

É importante compreender que Inteligência Artificial (IA) e Aprendizagem Automática (ML) não são a mesma coisa, mas estão intimamente relacionadas.

- **A ML é uma ferramenta fundamental para a IA:** pense na IA como o objetivo principal de criar máquinas inteligentes. A ML é uma das ferramentas e abordagens chave que utilizamos para alcançar este objetivo, permitindo que os sistemas de IA adquiram inteligência através da aprendizagem a partir dos dados.
- **Relação sinérgica:** IA e ML trabalham em conjunto. A IA define o objetivo (criar máquinas inteligentes) e o ML fornece as capacidades de aprendizagem que tornam essas máquinas inteligentes. Esta parceria sustenta muitas ferramentas educativas; muitas das ferramentas de IA que usamos na educação dependem da Aprendizagem Automática.
- **A Evolução da IA e a Ascensão da Aprendizagem Automática:** Com o tempo, a Aprendizagem Automática tornou-se cada vez mais importante no campo da IA. Tornou-se uma força motriz chave por detrás de muitos dos avanços recentes na IA.
- **O futuro da IA e da ML:** O que acontece a seguir na IA estará intimamente ligado à forma como a aprendizagem automática continua a evoluir. A literacia em IA (que inclui a compreensão da aprendizagem automática) é crucial para que os educadores estejam preparados e possam orientar-se para o futuro da educação.

## 1.3 A importância da literacia em IA e ML para educadores

No século XXI, a IA já não é uma tecnologia de nicho; tornou-se parte integrante do nosso dia a dia e uma força motriz por detrás da mudança social. Por isso, o desenvolvimento **da literacia em IA** é crucial para todos, especialmente para os educadores.

A literacia em IA refere-se à capacidade de compreender e utilizar eficazmente as tecnologias de IA, avaliar criticamente as suas aplicações e considerar as suas implicações éticas e sociais.

Eis porque é que a literacia em IA é tão importante na educação, abordando diretamente as necessidades de formação e as sugestões de melhoria expressas no relatório:

### 1.3.1 Preparar os alunos para o futuro

A IA está a transformar o mundo do trabalho, e os aprendentes precisam de estar preparados para este cenário em mudança. A literacia em IA equipa-os com as competências e conhecimentos de que necessitam para:

- **Adaptar-se a locais de trabalho** orientados por IA**:** Muitos empregos estão a ser melhorados ou transformados pela IA, e novos papéis estão a surgir. Os estudantes devem ser capazes de trabalhar em conjunto com sistemas de IA, compreender as suas capacidades e limitações, e contribuir com as suas competências humanas únicas. Isto inclui competências como pensamento crítico, criatividade, resolução de problemas complexos e colaboração, que são essenciais para navegar no futuro do trabalho.
- **Seguir carreiras em áreas relacionadas com IA:** A procura por especialistas em IA está a crescer rapidamente. A literacia em IA pode inspirar os estudantes a seguir carreiras em ciência da computação, ciência de dados, engenharia e outras áreas que contribuem para o desenvolvimento e aplicação da IA.
- **Tornar-se cidadãos informados numa sociedade impulsionada pela IA:** A IA está a influenciar vários aspetos da sociedade, desde a saúde e transportes até à comunicação e entretenimento. Os estudantes precisam de compreender as implicações da IA para poderem participar em discussões informadas sobre o seu uso, regulamentação e considerações éticas. Isto inclui compreender os potenciais benefícios e riscos da IA, bem como a importância da inovação responsável.

💡 Pontos de Debate em Sala de Aula e Cenários do Mundo Real:

**O aprendiz 'padrão':** Se treinarmos um modelo para reconhecer a 'boa postura' usando apenas fotografias de alunos sentados em cadeiras normais, a IA não conseguirá reconhecer um aluno brilhante usando uma secretária de pé ou uma cadeira de rodas?

**Viés cultural:** Se treinarmos uma IA para reconhecer "alimentos de pequeno-almoço" usando apenas imagens ocidentais (cereais, torradas), o que ela classificará quando vir um pequeno-almoço tradicional da Turquia, Grécia ou Ásia?

Para preparar eficazmente os alunos, os próprios educadores precisam de ter conhecimentos básicos sobre IA. Isto significa:

- **Compreender conceitos básicos de IA:** Os educadores devem ter uma compreensão fundamental do que é IA, como funciona e das suas diferentes aplicações. Isto inclui familiaridade com termos-chave como aprendizagem automática, redes neuronais e algoritmos.
- **Manter-se atualizado com os avanços em** IA**:** O campo da IA está em constante evolução, pelo que os educadores precisam de se manter informados sobre os últimos desenvolvimentos e tendências. Isto pode envolver ler artigos, participar em workshops ou frequentar cursos online.
- **Avaliar ferramentas e recursos de IA:** Os educadores precisam de ser capazes de avaliar criticamente a qualidade, eficácia e implicações éticas das ferramentas e recursos de IA antes de os integrar nas suas práticas de ensino. Isto inclui ter em conta fatores como preconceito, privacidade e acessibilidade.
- **Integrar a IA no currículo:** Os educadores devem ser capazes de incorporar conceitos e aplicações de IA no seu currículo de forma significativa e envolvente. Isto pode envolver o desenho de projetos relacionados com IA, a utilização de ferramentas de IA para melhorar a aprendizagem ou a discussão das implicações éticas da IA em diferentes contextos.

### 1.3.2 Avaliação e seleção de ferramentas de IA

O rápido crescimento da IA levou à proliferação de ferramentas e recursos alimentados por IA para a educação. Os educadores precisam de ser capazes de avaliar criticamente estas ferramentas e selecionar as mais adequadas para os seus alunos e objetivos de ensino. Este processo envolve considerar vários fatores:

- **Alinhamento com os objetivos de aprendizagem:** A ferramenta de IA escolhida deve apoiar diretamente os objetivos específicos de aprendizagem da aula ou atividade. Deve ser claro como a ferramenta irá contribuir para que os alunos alcancem os resultados de aprendizagem desejados.

- **Solidez pedagógica:** A ferramenta deve basear-se em princípios pedagógicos sólidos e promover práticas eficazes de ensino e aprendizagem. Não deve ser apenas uma novidade tecnológica, mas sim uma ferramenta que melhore a experiência de aprendizagem.
- **Facilidade de utilização:** A ferramenta deve ser intuitiva tanto para professores como para alunos. Navegar, compreender e utilizá-la eficazmente deve ser simples. Ferramentas complexas ou pesadas podem dificultar o processo de aprendizagem. **É precisamente aqui que o Teachable Machine se destaca, devido à sua natureza altamente intuitiva.**
- **Acessibilidade e inclusão:** A ferramenta deve ser acessível a todos os aprendizes, incluindo aqueles com deficiências ou necessidades de aprendizagem diversificadas. Deve também ser inclusiva e evitar perpetuar preconceitos ou estereótipos.
- **Privacidade e segurança dos dados:** Proteger os dados dos alunos e garantir a sua privacidade é fundamental para a ferramenta. Os educadores devem estar plenamente cientes das políticas de recolha e utilização de dados de qualquer ferramenta de IA que pretendam utilizar.
- **Implicações éticas:** As potenciais implicações éticas da ferramenta, como preconceito, equidade e transparência, devem ser cuidadosamente avaliadas. Os educadores devem considerar como a ferramenta pode afetar diferentes grupos de alunos e se levanta alguma preocupação ética.
- **Custo-benefício:** A ferramenta deve oferecer um bom retorno do investimento, ao mesmo tempo que se revela economicamente vantajosa. Os educadores devem ponderar o custo da ferramenta em relação aos seus benefícios e explorar se existem alternativas mais acessíveis.

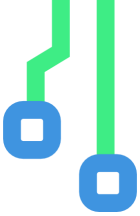
### 1.3.3 Integração da IA no Currículo

Integrar a IA no currículo é essencial para proporcionar aos alunos uma educação abrangente e relevante no século XXI. Isto vai além da simples utilização de ferramentas de IA na sala de aula; envolve ensinar os alunos sobre a própria IA. Aqui estão algumas estratégias eficazes para integrar a IA no currículo:

- **Aulas dedicadas à IA:** Incorpore disciplinas ou unidades específicas sobre conceitos, aplicações e implicações éticas da IA. Estas aulas podem abordar temas como: O que é IA? Como funciona a IA? Tipos de IA (por exemplo, aprendizagem automática, processamento de linguagem natural). Aplicações da IA em diferentes áreas. Considerações éticas em IA.
- **Aprendizagem baseada em projetos:** Envolver os alunos em projetos práticos que envolvam o uso ou desenvolvimento de IA. A aprendizagem baseada em projetos oferece aos alunos oportunidades de aplicar os seus conhecimentos e competências num contexto significativo. Exemplos de projetos relacionados com IA incluem: Desenvolver um modelo simples de IA usando a Teachable Machine. Criar um chatbot alimentado por IA. Desenhar uma solução de IA para um problema do mundo real.
- **Ligações Interdisciplinares:** Integrar conceitos e aplicações de IA noutras disciplinas, como matemática, ciências, estudos sociais e linguagem e literatura. Isto ajuda os alunos a perceber a relevância da IA em diferentes disciplinas e promove a aprendizagem interdisciplinar. Exemplos de ligações interdisciplinares incluem: Utilização de IA para analisar dados em experiências científicas. Exploração das implicações éticas da IA em discussões de estudos sociais. Utilização de IA para gerar temas de escrita criativa em linguagem e literatura.
- **Exemplos e estudos de caso do mundo real:** Use exemplos e estudos de caso reais para ilustrar conceitos e aplicações de IA. Isto ajuda os alunos a compreender como a IA está a ser usada no mundo real e o seu impacto na sociedade. Exemplos incluem: Discussão sobre o uso da IA nos cuidados de saúde para diagnóstico de doenças. Análise do papel da IA nas redes sociais e o seu impacto na comunicação. Análise dos dilemas éticos colocados pelos carros autónomos.

## 1.4 IA como ferramenta pedagógica: benefícios para professores e alunos

A Inteligência Artificial não é apenas uma disciplina a ser estudada; é também uma ferramenta poderosa que pode ser aproveitada tanto por professores como por alunos para enriquecer a

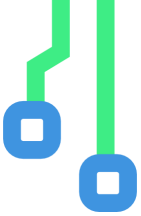


experiência de aprendizagem, melhorar as práticas de ensino e promover a inovação na educação. Compreender estes benefícios é crucial para educadores que pretendem integrar a IA de forma eficaz nas suas salas de aula.

### 1.4.1 IA para aprendizagem personalizada: adaptar a educação às necessidades individuais

Uma das aplicações mais promissoras da IA na educação é a sua capacidade de personalizar as experiências de aprendizagem dos alunos. Os alunos aprendem a ritmos diferentes, têm estilos de aprendizagem diferentes e possuem pontos fortes e fracos distintos. A IA pode ajudar a abordar estas diferenças individuais e criar caminhos de aprendizagem mais personalizados.

- **Plataformas de aprendizagem adaptativa:** Estas plataformas baseadas em IA ajustam-se dinamicamente às necessidades individuais de cada aluno através de:
    - Avalie os seus conhecimentos e competências atuais.
    - Forneça conteúdos e atividades de aprendizagem personalizadas.
    - Ajusta o nível de dificuldade com base no desempenho dos alunos.
    - Forneça feedback e apoio direcionados. Estas plataformas podem ajudar os alunos a aprender ao seu próprio ritmo, a focar-se nas áreas onde mais precisam de apoio e a receber orientação personalizada.
- **Percursos de aprendizagem personalizados:** Os dados dos aprendizes podem ser analisados por IA para identificar estilos de aprendizagem, preferências e pontos fortes individuais. Esta informação é depois usada para criar percursos de aprendizagem personalizados, especificamente adaptados às necessidades de cada aprendiz. Por exemplo, alguns aprendentes podem aprender melhor através de imagens visuais, enquanto outros podem preferir atividades práticas. A IA ajuda a identificar estas preferências e a fornecer materiais de aprendizagem no formato mais eficaz para cada aprendiz.
- **Sistemas inteligentes de tutoria:** Estes sistemas de tutoria baseados em IA fornecem instrução e apoio individualizados aos alunos. As suas capacidades incluem:



- Responda às perguntas dos alunos.
- Forneça orientação passo a passo.
- Dê feedback sobre o trabalho dos alunos.
- Simule um tutor humano, proporcionando atenção e apoio personalizados. Sistemas inteligentes de explicações podem ser particularmente benéficos para alunos que precisam de ajuda extra ou que têm dificuldades com conceitos específicos.

- **Feedback e avaliação personalizados:** O trabalho dos alunos pode ser analisado por IA para fornecer feedback personalizado sobre os seus pontos fortes e fracos. Este feedback, adaptado às necessidades individuais de cada aluno, ajuda-os a identificar áreas de melhoria e a acompanhar o seu progresso ao longo do tempo. A IA também automatiza certos aspetos da avaliação, como a correção de perguntas de escolha múltipla ou o feedback inicial em trabalhos escritos. Esta capacidade liberta tempo para os professores, permitindo-lhes focar-se mais no apoio individualizado ao aluno.

### 1.4.2 IA para melhorar o ensino: capacitar os educadores com ferramentas inteligentes

A IA também funciona como uma ferramenta valiosa para os professores, proporcionando novas vias para melhorar as práticas de ensino, automatizar tarefas e obter perceções sobre a aprendizagem dos alunos.

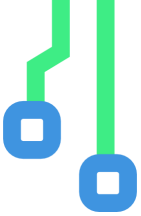
- **Automatização de tarefas administrativas:** Muitas tarefas administrativas normalmente realizadas por professores podem ser automatizadas por IA. Estas incluem:
  - Correção de trabalhos simples.
  - Registo de presença.
  - Agende reuniões.
  - Comunique com os pais. Isto pode libertar tempo para que os professores se concentrem em tarefas mais importantes, como planear as aulas, fornecer apoio individualizado aos alunos e envolver-se no desenvolvimento profissional.

- **Fornecimento de insights baseados em dados:** Os dados dos alunos podem ser analisados por IA para oferecer aos professores informações sobre a aprendizagem dos alunos. Esta capacidade ajuda os professores:
    - Identifique alunos com dificuldades.
    - Acompanhe o progresso dos alunos.
    - Identifique as áreas onde o currículo pode precisar de ser ajustado.
    - Tome decisões baseadas em dados sobre as suas práticas de ensino.
- **Criação de recursos de aprendizagem personalizados:** Os professores podem ser grandemente ajudados pela IA no desenvolvimento de recursos de aprendizagem personalizados para os seus alunos. Isto pode envolver:
    - Gerar folhas de trabalho personalizadas.
    - Criação de questionários interativos.
    - Desenvolver percursos de aprendizagem personalizados.
    - Adaptar os recursos às necessidades e interesses específicos dos seus alunos.
- **Apoio a alunos com necessidades especiais:** A IA oferece um apoio significativo a alunos com necessidades especiais. Esta tecnologia pode:
    - Fornecer tecnologias assistivas.
    - Personalizar os materiais de aprendizagem.
    - Oferecer apoio individualizado. A IA pode ajudar a criar um ambiente de aprendizagem mais inclusivo para todos os alunos.

### 1.4.3 IA para acessibilidade e inclusão

A IA tem um potencial significativo para melhorar a acessibilidade e a inclusão na educação para todos os alunos, incluindo aqueles com deficiências ou necessidades de aprendizagem diversas.

- **Tecnologias assistivas:** A IA sustenta várias tecnologias assistivas que ajudam os alunos com deficiência a aceder e interagir com materiais de aprendizagem. Exemplos incluem:
    - Leitores de ecrã: Ferramentas baseadas em IA convertem texto em fala, tornando assim o conteúdo digital acessível a estudantes com deficiências visuais.



- Software de voz para texto: Esta tecnologia de IA transforma palavras faladas em texto, permitindo que alunos com deficiências físicas escrevam e comuniquem com mais facilidade.
- Ferramentas de tradução: Ao traduzir texto e fala para diferentes línguas, a IA torna os materiais de aprendizagem acessíveis aos alunos que estão a aprender inglês.

- **Adaptações de aprendizagem personalizadas:** A personalização das adaptações de aprendizagem para aprendizes com deficiências ou necessidades de aprendizagem diversas é facilitada pela IA. Isto pode envolver:
  - Fornecer formatos alternativos para materiais de aprendizagem.
  - Ajust o ritmo da instrução.
  - Oferecer apoio individualizado. A IA pode ajudar a criar um ambiente de aprendizagem adaptado às necessidades específicas de cada aluno.
- **Identificação precoce de dificuldades de aprendizagem:** A análise dos dados dos alunos através de IA permite identificar os alunos que podem estar em risco de dificuldades de aprendizagem. Esta capacidade facilita a intervenção e o apoio precoces, ajudando eficazmente os alunos a superar desafios e alcançar o sucesso escolar.
- **Criação de ambientes de aprendizagem inclusivos:** Ambientes de aprendizagem mais inclusivos são promovidos ativamente graças à capacidade da IA de:
  - Automatizar tarefas que possam ser desafiantes para alguns alunos.
  - Oferecer apoio personalizado.
  - Criar oportunidades para que todos os alunos participem e participem na aprendizagem.

### 1.4.4 IA para Avaliação e Feedback

As práticas de avaliação e feedback na educação podem ser transformadas pela IA, proporcionando a professores e alunos formas mais eficientes, personalizadas e perspicazes de medir a aprendizagem e acompanhar o progresso.

- **Avaliação automática:** Certos tipos de avaliações podem ser avaliadas automaticamente através de IA. Estas incluem:
    - Perguntas de escolha múltipla.
    - Perguntas de resposta curta.
    - Ensaios. Isto pode libertar tempo para que os professores se concentrem em dar feedback mais personalizado aos alunos e se concentrarem noutras atividades pedagógicas.
- **Feedback personalizado:** O trabalho dos alunos pode ser analisado por IA para fornecer feedback personalizado sobre os seus pontos fortes e fracos. Este feedback, adaptado às necessidades individuais de cada aluno, ajuda-os a identificar áreas a melhorar e a acompanhar o progresso ao longo do tempo.
- **Avaliação formativa:** A criação de avaliações formativas que forneçam feedback contínuo aos alunos sobre a sua aprendizagem é possível através da IA. Estas avaliações servem para que:
    - Acompanhe o progresso dos alunos.
    - Identifique áreas onde os alunos têm dificuldades.
    - Ajuste o ensino para responder às necessidades dos alunos.
- **Testes adaptativos:** A IA permite a criação de testes adaptativos que ajustam a dificuldade das perguntas com base no desempenho dos alunos. Isto proporciona uma avaliação mais precisa dos conhecimentos e competências dos alunos e pode ajudar a reduzir a ansiedade em relação aos testes.
- **Análise dos dados de aprendizagem dos alunos:** Os dados de aprendizagem dos alunos são analisados por IA para fornecer aos professores informações sobre o progresso dos alunos e identificar áreas onde o currículo pode necessitar de ajustes. Esta abordagem de avaliação baseada em dados contribui para uma maior eficácia do ensino.

### 1.4.5 IA para a criação de conteúdos educativos

A assistência na criação de conteúdos educativos é um benefício significativo da IA, facilitando aos professores o desenvolvimento de materiais de aprendizagem envolventes e eficazes.

- **Geração de perguntas e questionários de formação:** A IA gera perguntas e questionários de formação sobre vários temas, proporcionando aos formandos oportunidades para rever e testar os seus conhecimentos.
- **Criar simulações interativas e ambientes virtuais:** Utilizar IA permite-lhe criar simulações interativas e ambientes virtuais, permitindo que os alunos explorem e aprendam de forma segura e envolvente.
- **Desenvolvimento de materiais de aprendizagem personalizados:** Os professores recebem apoio da IA para desenvolver materiais de aprendizagem personalizados adaptados às necessidades e interesses específicos dos seus alunos.
- **Tradução e adaptação de conteúdos:** A IA traduz conteúdos educativos para diferentes línguas e adapta-os a vários contextos culturais, aumentando assim a sua acessibilidade a uma gama mais ampla de aprendentes.

### 1.4.6 IA para desenvolvimento profissional

A IA também pode ser utilizada para apoiar o desenvolvimento profissional dos professores, proporcionando-lhes oportunidades para aprender novas competências, melhorar as suas práticas de ensino e manter-se atualizado com os avanços mais recentes na educação.

Apoiar o desenvolvimento profissional dos professores é outra área em que a IA é altamente benéfica. Oferece aos educadores oportunidades para aprender novas competências, melhorar as práticas de ensino e manter-se atualizado com os avanços mais recentes na educação.

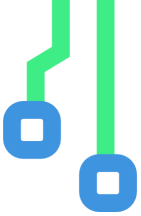
- **Desenvolvimento profissional personalizado:** A IA analisa os dados dos professores para fornecer recomendações personalizadas de desenvolvimento profissional. Isto ajuda os professores a focar-se nas áreas a melhorar e a aceder aos recursos mais relevantes para as suas necessidades.
- **Mentoria e mentoria virtuais:** A IA oferece mentoria e mentoria virtuais aos professores, fornecendo feedback sobre as suas práticas de ensino e apoiando o seu crescimento profissional.

- **Acesso a recursos e comunidades online:** Os professores podem aceder a recursos e comunidades online através de IA, onde podem partilhar ideias, colaborar com colegas e aprender com especialistas na área.
- **Feedback baseado em dados sobre práticas de ensino:** A IA analisa dados da sala de aula para fornecer feedback aos professores sobre as suas práticas de ensino. Esta abordagem orientada por dados ajuda os professores a identificar áreas a melhorar e a aperfeiçoar as suas estratégias de ensino.

## 1.5 Para além das disciplinas STEM: IA noutras disciplinas

A Inteligência Artificial não se limita a aulas de ciência da computação ou matemática; é uma ferramenta interdisciplinar que enriquece a aprendizagem em todas as disciplinas:

- **História e Humanidades:** Explique como o Machine Learning (ML) ajuda os investigadores a ler pergaminhos antigos e danificados, treinando modelos para reconhecer padrões de tinta ténues invisíveis ao olho humano, ou como a IA analisa arquivos históricos para categorizar artefactos.
- **Música e Arte:** Discuta como a IA pode analisar o "estilo de pinceladas" dos pintores ou os "padrões de tempo" de diferentes géneros musicais para ajudar a categorizar a história da arte. Os alunos também podem explorar a IA como parceiro criativo para arte digital generativa e composição musical.
- **Línguas e Literatura:** Explore como o processamento de linguagem natural e o reconhecimento de fala ajudam na aquisição de língua, análise dialetal e análise automatizada de sentimento (por exemplo, treinar um modelo para detetar um tom positivo ou negativo na narrativa).
- **Ética e Estudos Sociais: Utilize** a IA como lente para analisar a cidadania digital, discutindo como os algoritmos influenciam os feeds de notícias, as recomendações das redes sociais e o acesso à informação a nível global.



# Módulo 2: Introdução à Máquina Aprendível: O Seu Laboratório de Criação de IA

Depois de compreender o básico de Inteligência Artificial e Aprendizagem Automática, é altura de explorar uma ferramenta concebida para dar vida a estes conceitos na sua sala de aula: a Máquina Aprendível. Esta plataforma simplifica significativamente o processo de criação de modelos de IA, tornando-o acessível tanto para si como para os seus alunos.

## 2.1 Explorando a Máquina Aprendível: IA para Todos

Teachable Machine é uma ferramenta baseada na web, desenvolvida pela Google, que visa tornar o Machine Learning (ML) acessível e compreensível para todos, independentemente da sua formação técnica. Representa um passo significativo para a democratização da IA.

Esta plataforma permite aos utilizadores criar os seus próprios modelos de ML diretamente através de uma interface intuitiva, sem necessidade de escrever uma única linha de código. Esta capacidade é revolucionária porque, tradicionalmente, construir modelos de ML exigia conhecimentos especializados de linguagens de programação, conceitos matemáticos complexos e bibliotecas específicas de ML.

> **Democratização da IA:** Historicamente, a Aprendizagem Automática era um domínio reservado a especialistas com conhecimentos e competências especializadas em ciência da computação, estatística e áreas relacionadas. Esta limitação restringia a sua acessibilidade, impedindo muitas pessoas de explorar o seu vasto potencial. A Teachable Machine pretende derrubar estas barreiras, capacitando um público mais vasto — incluindo educadores, artistas, estudantes e qualquer pessoa com uma ideia criativa — para aproveitar o poder da aprendizagem automática de formas inovadoras e práticas. Coloca efetivamente ferramentas de criação de IA nas mãos daqueles que talvez não tivessem acesso a elas anteriormente.

### 2.1.1 Principais Funcionalidades e Funcionalidades

Teachable Machine oferece uma abordagem única e intuitiva para explorar os conceitos fundamentais de Aprendizagem Automática e construir modelos práticos de ML. O seu design privilegia a simplicidade e a acessibilidade.

- **Interface simples:** Uma interface visual, intuitiva e interativa orienta os utilizadores durante todo o processo de criação e treino de modelos de ML. Esta interface foi concebida para ser autoexplicativa e fácil de navegar, mesmo para pessoas sem experiência prévia em ML.
- **Três tipos de projetos:** Os utilizadores podem criar projetos centrados em três tipos principais de dados usando a Teachable Machine:
    - **Projetos de imagem:** estes projetos permitem o treino de modelos capazes de reconhecer e classificar diferentes imagens.
    - **Projetos de áudio:** Os modelos treinados aqui conseguem reconhecer e classificar vários sons.

- **Designs de poses:** Com estes, os utilizadores podem treinar modelos para reconhecer e classificar diferentes poses corporais. Esta variedade proporciona uma flexibilidade substancial, permitindo aos utilizadores explorar uma vasta gama de aplicações de ML.

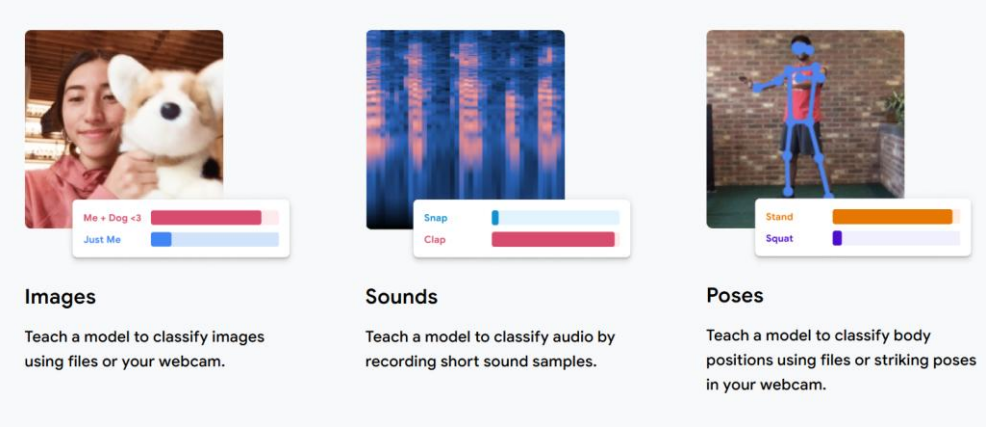



Imagem 1: Tipos de Designs de Máquinas Ensinables

- **Ferramentas de recolha de dados:** A plataforma simplifica o processo de recolha dos dados necessários para treinar modelos de ML. Inclui ferramentas integradas que permitem aos utilizadores:
  - Captar imagens ou poses diretamente através da webcam.
  - Gravar amostras de áudio usando o microfone.
  - Carreguar dados existentes de imagens, áudio ou poses a partir do seu computador ou de outras fontes. Estas funcionalidades facilitam a criação de conjuntos de dados personalizados adaptados às necessidades específicas de cada projeto.
- **Treino e exportação de modelos:** A plataforma gere as complexidades técnicas do treino de modelos de ML em segundo plano, aliviando as preocupações dos utilizadores sobre os algoritmos ou o código subjacente. Uma vez treinado o modelo, o Teachable Machine permite que seja exportado em vários formatos para utilização noutros projetos ou aplicações. Esta funcionalidade permite integrar os modelos de ML criados em websites, aplicações e outras experiências digitais.

### 2.1.2 Como a Máquina Aprendível Simplifica o Aprendizado Automático

O Teachable Machine reduz significativamente as barreiras à criação de modelos de Aprendizagem Automática, tornando o Aprendizagem Automática mais acessível e fácil de abordar para um público mais vasto.

- **Não é necessário código:** Uma das formas mais significativas de o Teachable Machine simplificar o ML é eliminando a necessidade de programação. Os utilizadores podem construir modelos sofisticados de ML sem escrever uma única linha de código, abrindo o ML a indivíduos que possam não possuir competências de programação.
- **Aprendizagem visual:** A plataforma dá ênfase à aprendizagem visual, oferecendo feedback visual ao longo de todo o processo de criação do modelo. Isto ajuda os utilizadores a compreender conceitos fundamentais de ML, como os modelos são treinados, como os dados são usados e como são feitas as previsões.
- **Experiência prática:** A Máquina Teachable incentiva a experimentação, a exploração e a criatividade. Proporciona um ambiente de aprendizagem prática onde os utilizadores adquirem conhecimento através da ação, construção de projetos e observação de resultados em tempo real. Esta abordagem de aprendizagem ativa promove uma compreensão mais profunda do ML e das suas potenciais aplicações.

### 2.1.3 Por que usar a Máquina Aprendível na Educação? Principais Benefícios

A Teachable Machine oferece um conjunto único e apelativo de benefícios para educadores que pretendem introduzir conceitos de Inteligência Artificial (IA) e Aprendizagem Automática (ML) na sala de aula. Proporciona uma forma prática, envolvente e acessível para estudantes de todas as idades e origens aprenderem e interagirem com estas tecnologias transformadoras, promovendo uma compreensão mais profunda e desenvolvendo competências essenciais para o futuro.

- **Acessibilidade e facilidade de uso:** A interface extremamente intuitiva e a abordagem inovadora sem código da Teachable Machine tornam-na excecionalmente acessível tanto para alunos como para professores, independentemente dos seus conhecimentos técnicos prévios ou proficiência em programação. Esta facilidade de utilização é uma vantagem crucial na educação, permitindo aos educadores integrar ML nas aulas de forma fluida, sem necessidade de formação especializada, preparação completa ou investimentos significativos em software ou hardware complexo. Os professores podem focar-se nos aspetos pedagógicos do ensino de IA e ML, em vez de se perderem em complexidades técnicas. Esta acessibilidade estende-se também aos alunos, pois a Teachable Machine proporciona uma experiência de aprendizagem intuitiva e envolvente que não requer conhecimentos prévios de programação. Os alunos podem mergulhar diretamente na criação e treino de modelos de ML, explorando conceitos e experimentando diferentes aplicações, o que promove uma sensação de autonomia e apropriação da sua aprendizagem.
- **Aprendizagem prática e envolvimento:** A aprendizagem ativa e prática é fortemente promovida pela Teachable Machine, oferecendo aos estudantes a oportunidade de criar

os seus próprios projetos de Aprendizagem Automática do início ao fim. Esta abordagem de aprendizagem experiencial promove um envolvimento significativamente mais profundo e uma compreensão mais intuitiva e duradoura dos conceitos de ML, em comparação com métodos tradicionais que dependem principalmente de aulas ou manuais. Quando os estudantes participam ativamente na construção e treino dos seus próprios modelos de ML, têm muito mais probabilidade de compreender os princípios fundamentais de como estes sistemas funcionam, como os dados são usados e como são feitas as previsões. Aprendem através da prática, experimentação e observação dos resultados diretos das suas ações, o que conduz a uma experiência de aprendizagem mais profunda e significativa. Esta participação ativa também fomenta a curiosidade, incentivando os estudantes a explorar possibilidades, fazer perguntas e aprofundar o tema.

- **Criatividade e inovação:** A Teachable Machine capacita os alunos a libertar a sua criatividade e a aplicar a Aprendizagem Automática para resolver problemas do mundo real, enfrentar desafios comunitários ou criar projetos inovadores que expressem as suas ideias únicas. Incentiva o pensamento fora da caixa, a exploração de aplicações não convencionais da IA e o desenvolvimento de soluções pessoais significativas. Esta ênfase na criatividade e inovação é crucial na educação, pois promove o empreendedorismo, incentiva a resolução de problemas e prepara os alunos para serem adaptáveis e engenhosos num mundo em rápida mudança. A Teachable Machine oferece uma plataforma para os alunos transformarem ideias em projetos concretos, promovendo o sucesso e inspirando a exploração contínua das possibilidades da IA.
- **Desenvolvimento de competências essenciais:** Trabalhar com a Teachable Machine oferece aos alunos uma valiosa oportunidade de desenvolver uma vasta gama de competências essenciais altamente relevantes para o sucesso no século XXI e além. Estas competências não se aplicam apenas à ciência da computação ou tecnologia, mas também são transferíveis para várias disciplinas e percursos profissionais. A Teachable Machine ajuda os alunos a cultivar:
    - **Competências de resolução de problemas e pensamento crítico:** Ao desenhar e construir projetos de ML, os alunos aprendem a dividir problemas complexos em passos mais pequenos e geríveis, analisar dados, identificar padrões e desenvolver soluções lógicas. Também aprendem a avaliar a eficácia das suas soluções, identificar áreas a melhorar e aperfeiçoar abordagens.
    - **Pensamento computacional e competências de literacia de dados:** A Teachable Machine introduz os alunos aos princípios fundamentais do pensamento computacional, como a decomposição, reconhecimento de padrões, abstração e pensamento algorítmico. Também promove a literacia de dados ao ajudar os alunos

a compreender como os dados são recolhidos, organizados, interpretados e usados para treinar e avaliar modelos de ML.
    - **Criatividade e competências de inovação:** Esta ferramenta incentiva os alunos a pensar de forma criativa, explorar novas ideias e desenvolver soluções inovadoras usando ML. Proporciona uma plataforma para expressar perspetivas únicas, experimentar diferentes abordagens e criar projetos originais e impactantes.
    - **Colaboração e competências de comunicação:** Os projetos Teachable Machine podem fomentar eficazmente a colaboração entre os estudantes enquanto trabalham em conjunto para desenhar, construir e testar modelos de ML. Os estudantes aprendem a comunicar ideias de forma clara, partilhar conclusões, dar feedback construtivo aos colegas e trabalhar eficazmente em equipa. Estas competências não só são altamente relevantes para o futuro do trabalho, onde a IA e a automação desempenham um papel cada vez mais significativo, como também são amplamente aplicáveis e valiosas em várias disciplinas académicas, percursos profissionais e situações de vida.
- **Aplicações interdisciplinares:** Esta IA é uma ferramenta versátil, que se integra perfeitamente numa vasta gama de disciplinas e áreas de estudo, estendendo o seu valor educativo para além dos limites tradicionais do ensino das disciplinas STEM (ciência, tecnologia, engenharia e matemática). A sua adaptabilidade permite aos educadores relacionar conceitos de Aprendizagem Automática a diferentes áreas curriculares, promovendo a aprendizagem interdisciplinar e enriquecendo a experiência educativa. Aqui estão alguns exemplos de como a Teachable Machine pode ser integrada em diferentes disciplinas:
    - **Ciências:** Os alunos podem usar a Teachable Machine para construir modelos que classifiquem diferentes tipos de plantas ou animais, identificam padrões meteorológicos ou analisam dados científicos. Por exemplo, os alunos podem criar um projeto para identificar diferentes espécies de árvores com base em imagens de folhas, ou outro para classificar tipos de nuvens a partir de fotografias meteorológicas. Este tipo de aplicação melhora as capacidades de observação, o pensamento crítico e a compreensão do mundo natural dos alunos.
    - **Matemática:** Os alunos podem explorar análise de dados, reconhecimento de padrões e conceitos estatísticos através da criação e avaliação de modelos de aprendizagem automática.
    - **Artes:** Os alunos podem usar a Teachable Machine para criar instalações artísticas interativas, desenvolver novas formas de expressão musical ou desenhar projetos que respondam ao movimento ou som do corpo.

- **Humanidades:** Os alunos podem analisar imagens históricas ou gravações áudio, classificar diferentes tipos de documentos ou explorar o uso da linguagem em vários contextos.
- **Estudos Sociais:** Os estudantes podem investigar questões sociais, analisar demografias ou criar projetos que promovam a consciência social ou respondam a desafios comunitários. Esta aplicabilidade interdisciplinar faz da Teachable Machine uma ferramenta valiosa para fomentar a aprendizagem interdisciplinar, criar ligações entre diferentes disciplinas e demonstrar a ampla relevância da IA e da aprendizagem automática no mundo que nos rodeia.

## 2.2 Preparar o seu ambiente: Acesso e tipos de projetos

O Teachable Machine foi concebido para ser uma ferramenta de fácil acesso, minimizando os requisitos técnicos para que os utilizadores possam começar a criar projetos de Aprendizagem Automática. O seu principal modo de acesso é através de uma plataforma web, oferecendo várias vantagens em termos de conveniência e facilidade de utilização.

### 2.2.1 Acesso à Máquina Aprendível: Requisitos e Início

O Teachable Machine funciona essencialmente como uma aplicação web. Isto significa que corre diretamente no navegador web do utilizador, eliminando a necessidade de descarregar, instalar ou atualizar qualquer software. Os utilizadores podem aceder à plataforma a partir de qualquer computador ou dispositivo equipado com um navegador web compatível e uma ligação ativa à internet.

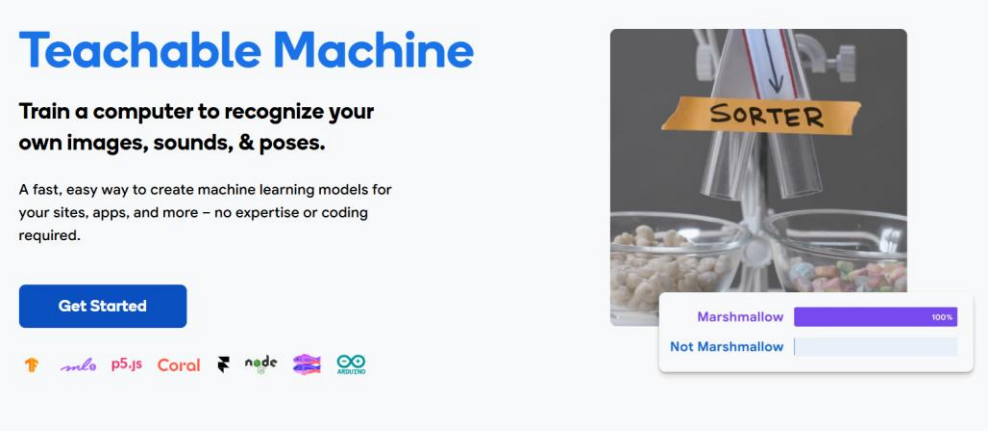



Imagem 2: Página de Destino da Máquina Ensinable

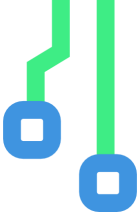
Esta abordagem baseada na web oferece flexibilidade e conveniência significativas, pois os utilizadores não estão limitados a um sistema operativo ou dispositivo específico. Quer esteja a

usar um PC com Windows, um computador com macOS, um Chromebook ou até um tablet com navegador web, pode aceder e usar o Teachable Machine sem quaisquer problemas de compatibilidade. Esta acessibilidade multiplataforma facilita a alternância entre dispositivos ou o trabalho em projetos a partir de diferentes locais sem interrupções.

Além disso, como o Teachable Machine funciona na cloud, os utilizadores não precisam de se preocupar com o espaço de armazenamento local do dispositivo. Os dados e modelos do projeto são geralmente guardados na conta Google do utilizador (caso optem por iniciar sessão), libertando assim recursos locais e garantindo acessibilidade ao projeto a partir de qualquer dispositivo.

Para utilizar a Teachable Machine de forma eficaz, os utilizadores geralmente precisam do seguinte:

- **Um navegador web compatível:** Teachable Machine foi concebido para funcionar com navegadores modernos como Google Chrome, Mozilla Firefox, Safari e Microsoft Edge. É importante utilizar uma versão atualizada do navegador para garantir desempenho e compatibilidade ótimos com todas as funcionalidades da plataforma.
- **Uma ligação à internet:** Como a Teachable Machine é uma aplicação baseada na web, é necessária uma ligação estável para aceder à plataforma, carregar dados do projeto, comboios e gravar o progresso. A velocidade da ligação à internet pode afetar os tempos de carregamento e o desempenho global da plataforma.
- **Uma conta Google (opcional, mas recomendada):** Embora seja possível experimentar o Teachable Machine sem iniciar sessão, criar uma conta Google permite aos utilizadores guardar e aceder aos seus projetos a partir de diferentes dispositivos. Isto é altamente recomendado para utilizadores que planeiam projetos com várias sessões ou que queiram fazer backup do seu trabalho.
- **Hardware para introdução de dados (dependendo do tipo de projeto):**
    - Para projetos de imagem e pose, é necessária uma webcam para captar imagens ou posar dados diretamente no navegador.
    - Para projetos de áudio, é necessário um microfone para gravar amostras de áudio. Os utilizadores também podem carregar dados de outras fontes, como ficheiros armazenados no seu computador ou dispositivos externos.



💡 Dica do professor

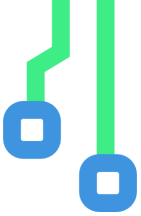
**Lista técnica prévia (para evitar problemas na sala de aula):**

- **Escolha do navegador:** O melhor desempenho é alcançado no **Google Chrome** ou **Microsoft Edge**. O Safari e o Firefox podem ter problemas de autorização de webcam ou microfone em certas redes escolares.
- **Conflitos de hardware:** Certifique-se de que webcams e microfones não estão a ser usados ativamente por ferramentas de videoconferência em segundo plano (como Zoom, Teams ou Google Meet) antes de abrir o Teachable Machine.
- **Firewall da escola:** Peça ao departamento de TI da sua escola para listar `teachablemachine.withgoogle.com` de sites autorizados para garantir que os modelos podem ser treinados, pré-visualizados e exportados sem bloqueios de rede.

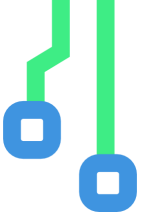
## 2.2.2 Compreender os tipos de projeto: Imagem, Áudio e Posição

O Teachable Machine oferece uma plataforma versátil que adapta a diferentes tipos de dados, permitindo aos utilizadores criar uma variedade de modelos de Aprendizagem Automática. Esta versatilidade reflete-se nos três tipos distintos de projetos disponíveis na plataforma: Projetos de Imagem, Projetos de Áudio e Projetos de Posição. Cada tipo de projeto é concebido para lidar com tipos de dados específicos e facilita a criação de modelos adaptados a aplicações específicas.

- **Projetos de Imagem:** Estes projetos em Teachable Machine permitem aos utilizadores construir modelos de Aprendizagem Automática capazes de analisar, classificar e reconhecer informação visual. O foco aqui está em treinar modelos para identificar e categorizar vários objetos, cenas ou padrões dentro das imagens.
  - **Funcionalidade:**
    - Os utilizadores podem carregar coleções de imagens ou capturá-las diretamente através da webcam para criar conjuntos de dados para treino de modelos.
    - A plataforma fornece ferramentas para definir diferentes 'classes' ou categorias, cada uma representando um objeto, cena ou conceito específico que o modelo aprenderá a reconhecer.
    - O modelo treinado pode então ser usado para classificar imagens novas e nunca antes vistas, determinando a sua categoria.
  - **Aplicações:** Os projetos de imagiologia são adequados para uma vasta gama de usos, incluindo:



        - **Reconhecimento de objetos:** Identificação de objetos específicos em imagens (por exemplo, ferramentas, animais, plantas).
        - **Classificação de imagens:** Categorize as imagens com base no conteúdo (por exemplo, paisagens, retratos, cenas interiores/exteriores).
        - **Classificação visual na sala de aula:** por exemplo, reconhecer diferentes tipos de folhas numa aula de ciências ou distinguir entre tipos de obras de arte numa aula de arte.
- **Projetos de Áudio:** Os utilizadores podem criar modelos de Aprendizagem Automática para analisar, classificar e reconhecer informação sonora através de Projetos de Áudio no Teachable Machine. Estes projetos focam-se em treinar modelos para identificar e categorizar vários sons, padrões de fala ou elementos musicais.
    - **Funcionalidade:**
        - Os utilizadores podem gravar amostras de áudio usando o microfone ou carregar ficheiros de áudio existentes para criar conjuntos de dados para treino de modelos.
        - A plataforma fornece ferramentas para definir diferentes "classes" ou categorias, cada uma representando um som, palavra, frase ou padrão áudio específico que o modelo aprenderá a reconhecer.
        - O modelo treinado pode então classificar novas amostras de áudio que nunca foram vistas antes, determinando a sua categoria.
    - **Aplicações:** Os Projetos de Áudio são adequados para várias aplicações, incluindo:
        - **Reconhecimento sonoro:** Identificação de sons específicos (por exemplo, sons de animais, ruídos ambientais, instrumentos musicais).
        - **Reconhecimento de fala:** Reconhecer e classificar palavras ou frases faladas.
        - **Classificação musical:** Categorizar as amostras de áudio com base no género, artista ou outras características musicais.
        - **Aplicações em sala de aula:** Reconhecer a pronúncia das palavras numa aula de língua ou identificar diferentes instrumentos musicais numa peça.
- **Desenhos de Postura:** Os Designs de Postura da Teachable Machine permitem aos utilizadores criar modelos de Aprendizagem Automática que analisam, classificam e reconhecem diferentes posturas e movimentos corporais. Estes projetos focam-se em modelos de treino para identificar e categorizar posturas, gestos ou movimentos específicos.
    - **Funcionalidade:**
        - Os utilizadores podem capturar dados de pose diretamente através da sua webcam para criar conjuntos de dados para o treino do modelo.



        - A plataforma fornece ferramentas para definir diferentes 'classes' ou categorias, cada uma representando uma pose, gesto ou movimento específico que o modelo aprenderá a reconhecer.
        - O modelo treinado pode então classificar poses ou movimentos novos e nunca antes vistos, determinando a sua categoria.
    - **Aplicações:** Os Desenhos de Postura revelam-se úteis para aplicações como:
        - **Reconhecimento de gestos:** Identificação de gestos manuais específicos ou movimentos corporais.
        - **Classificação do movimento:** categorização dos movimentos em desporto, dança ou fisioterapia.
        - **Instalações interativas:** Criação de sistemas que respondem aos movimentos do corpo.
        - **Exemplo em sala de aula:** Identificar se um aluno está sentado corretamente na cadeira ou a realizar um exercício de educação física de forma adequada. Ao oferecer estes três tipos distintos de projetos, a Teachable Machine oferece uma plataforma versátil para explorar uma vasta gama de aplicações de Aprendizagem Automática. A escolha do tipo de projeto depende dos objetivos específicos do utilizador e do tipo de dados com que pretende trabalhar.

### 2.2.3 Navegar pelo espaço de trabalho da Máquina Aprendível

O espaço de trabalho Teachable Machine foi concebido para ser intuitivo e fácil de usar, proporcionando um ambiente claro e despojado para criar e gerir projetos de Aprendizagem Automática. Embora o layout específico possa mudar ligeiramente com as atualizações da plataforma, os elementos centrais mantêm-se geralmente consistentes.

Aqui está uma descrição detalhada dos componentes típicos do espaço de trabalho:

- **Painel do projeto:** Quando acede pela primeira vez ao Teachable Machine, será apresentado um painel de controlo do projeto. Esta área funciona como um centro nervoso para gerir os seus projetos existentes. Aqui encontrará opções para:
    - Criar um novo projeto: Este botão ou link irá iniciar o processo de criação de uma nova imagem, áudio ou projeto de pose.
    - Veja os seus projetos existentes: Se já criou projetos antes, eles aparecerão aqui, permitindo-lhe aceder e editá-los.
    - Aceda a tutoriais ou recursos: Algumas plataformas podem fornecer links para documentação de apoio, tutoriais ou projetos de exemplo para o ajudar a começar.

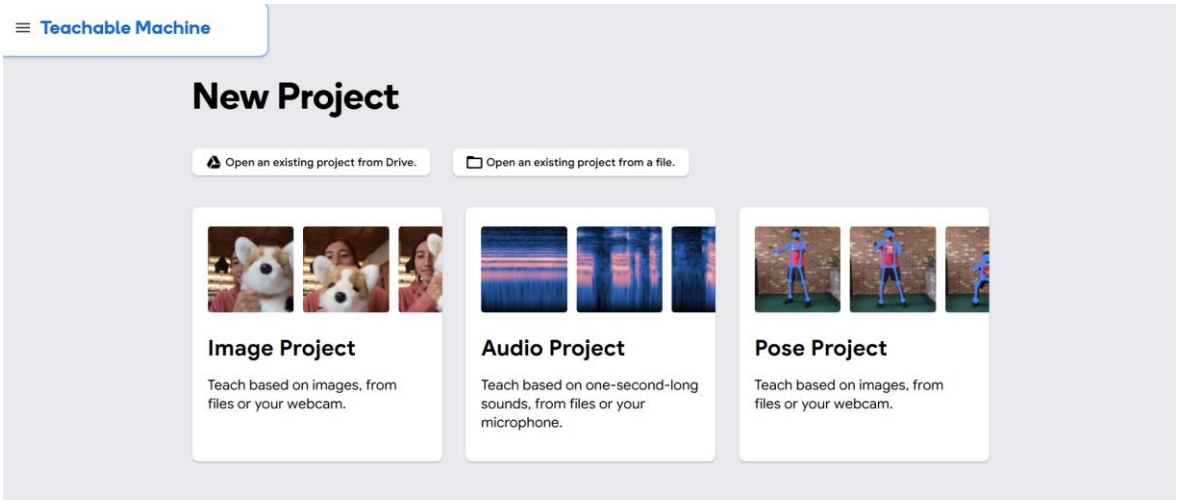



Imagem 3: Painel do Projeto Máquina Aprendível.

- **Vista de projeto:** Depois de selecionar ou criar um projeto, entra na vista principal do projeto. É aqui que vais passar a maior parte do tempo a trabalhar no teu modelo de ML. A vista de projeto está dividida em secções que te acompanham pelos passos-chave do fluxo de trabalho de ML: recolha de dados, treino de modelos e pré-visualização/exportação de modelos.

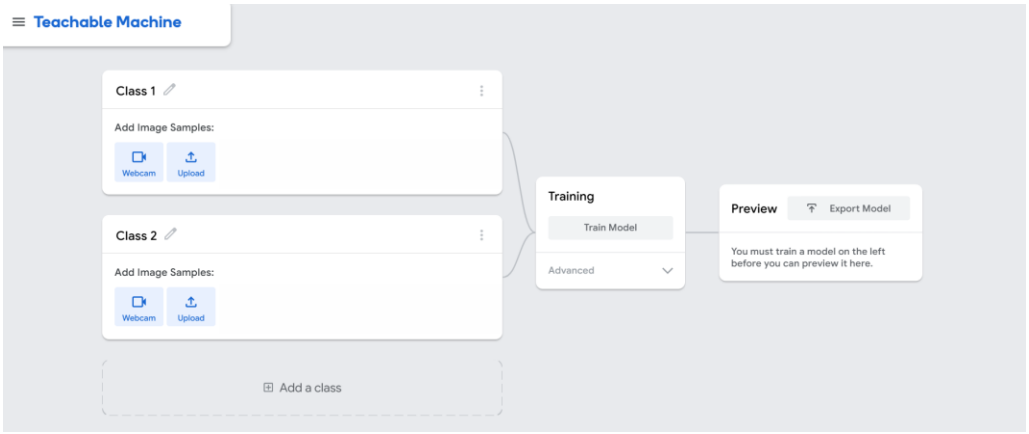



Imagem 4: Vista do projeto Teachable Machine.

- **Área de recolha de dados:** Esta secção é dedicada à recolha e gestão dos dados que irá usar para treinar o seu modelo de ML. Aqui encontrará:
    - Área de definição de classes: É aqui que defines as diferentes categorias ou "classes" que o teu modelo aprenderá a reconhecer. Normalmente podes adicionar novas classes, renomeá-las ou eliminá-las conforme necessário.

- Controlos de introdução de dados: Estes controlos permitem-lhe adicionar amostras de dados a cada turma. Dependendo do tipo de projeto, encontrará opções para:
  - Usar a sua webcam para captar imagens ou poses.
  - Usar o microfone para gravar amostras de áudio.
  - Carreguar ficheiros de dados do seu computador.
- Área de visualização de dados: Esta área mostra pré-visualizações ou miniaturas das amostras de dados que adicionou a cada aula, permitindo-lhe rever e gerir o seu conjunto de dados.

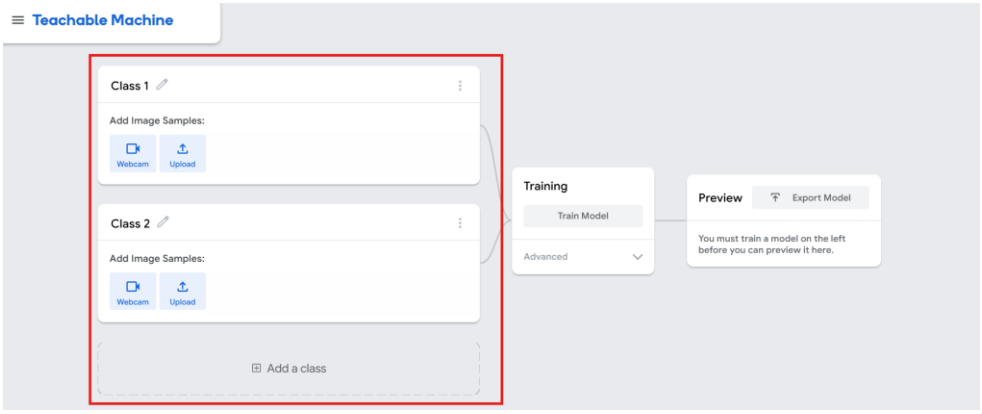



Imagem 5: Área de recolha de dados da Máquina Teachable.

- **Área de treino de modelos:** Esta secção foca-se no processo de treino do seu modelo de ML. Aqui encontrará:
  - Um botão "Modelo de Comboio": ao clicar neste botão, começa o processo de treino.
  - Indicadores de progresso do treino: A plataforma pode fornecer feedback visual para mostrar o progresso do modelo no treino. Isto inclui barras de progresso, mensagens ou animações.

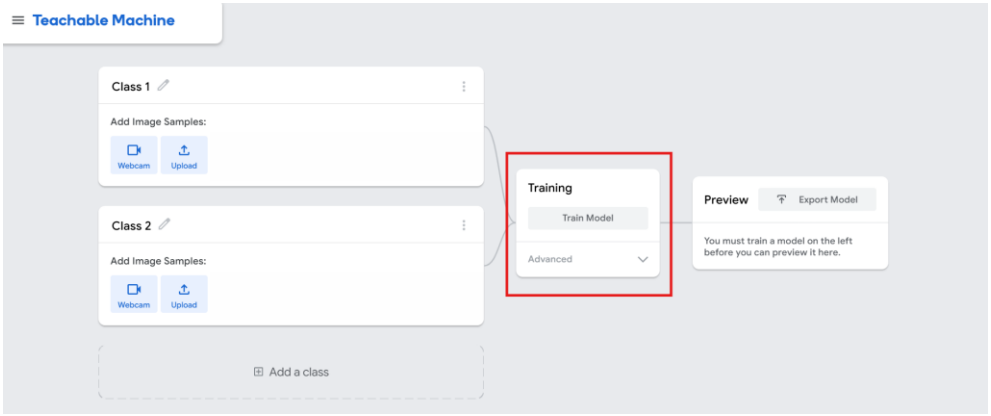


Imagem 6: Área de treino para modelos de máquinas ensinables.

- **Área de Pré-visualização/Resultados do Modelo:** Esta secção permite-lhe testar e interagir com o seu modelo de ML treinado. Vai encontrar:
    - Uma janela de pré-visualização: Esta área permite-lhe fornecer novos dados de entrada (por exemplo, através da webcam ou microfone) e observar como o seu modelo os classifica.
    - Exibição dos resultados: A plataforma irá mostrar as previsões do modelo, indicando a que classe identifica a que pertence a entrada.
    - Opções de exportação: Quando estiver satisfeito com o seu modelo, encontrará opções para o exportar em vários formatos.

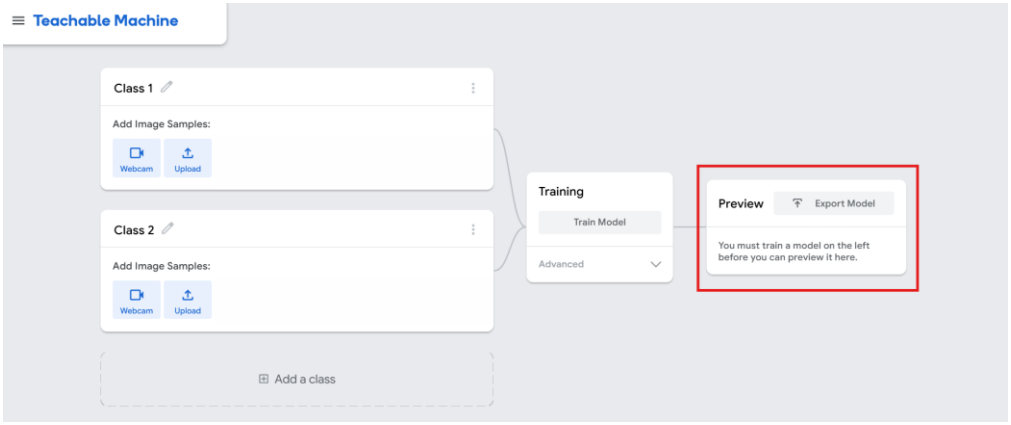


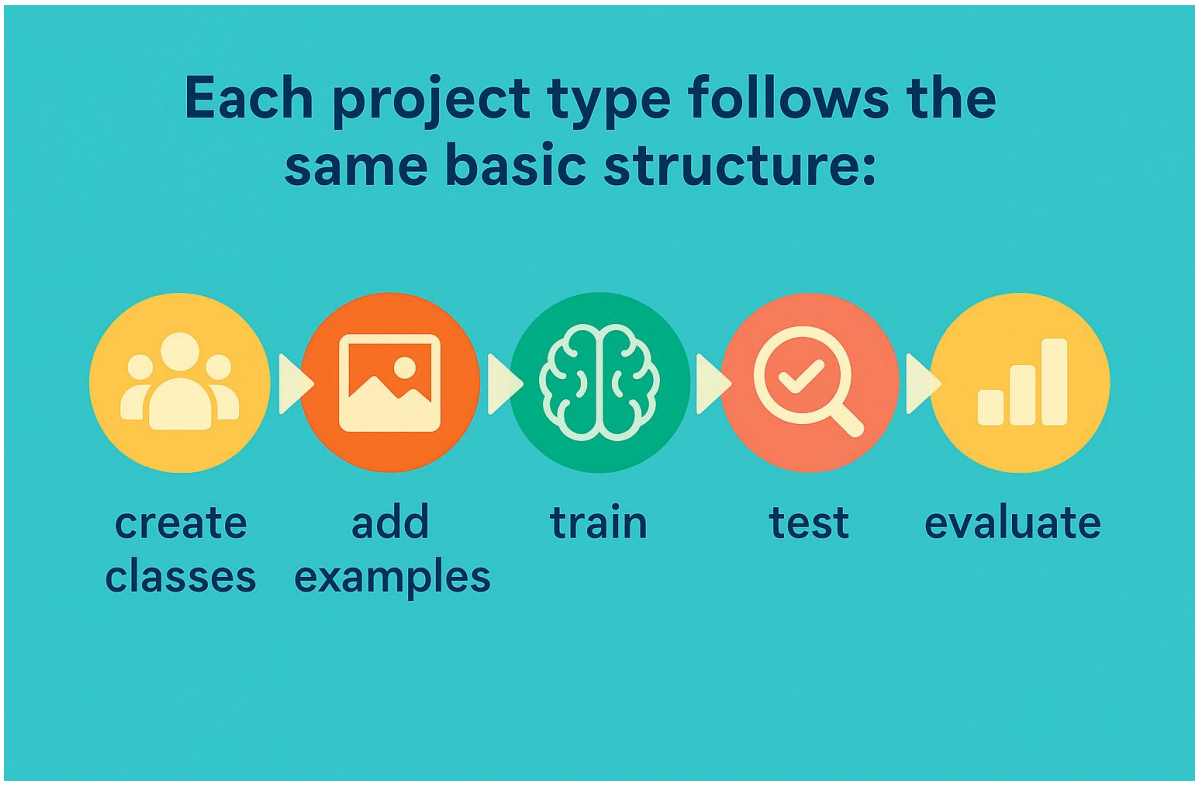

Imagem 7: Área de pré-visualização/resultados do modelo Teachable Machine.

💡 Dica do professor

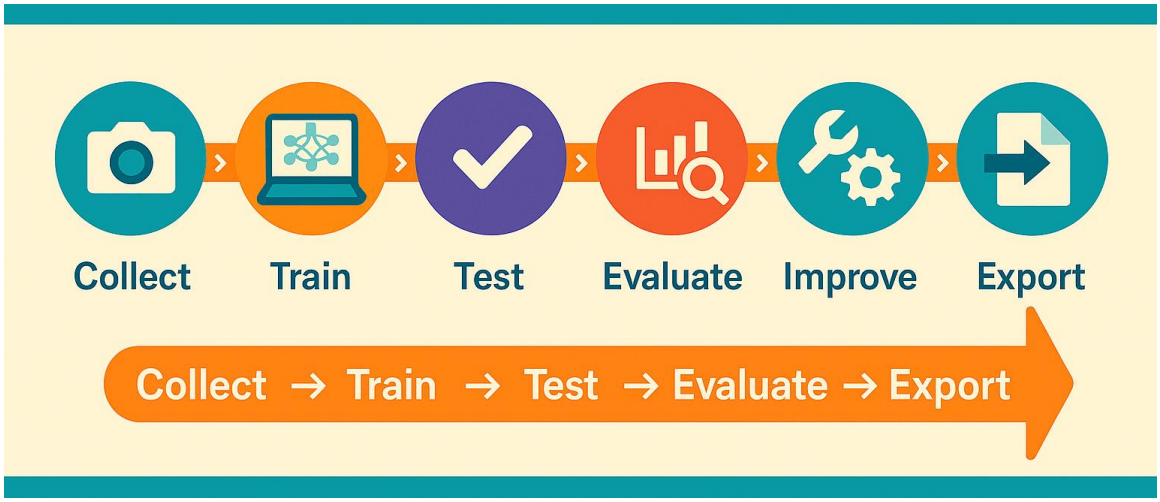
**Qual é a opção de exportação mais adequada para a sua turma?**

- **O link partilhável (a opção mais fácil e recomendada para a maioria das turmas):** Ideal para alunos do ensino básico e secundário enviarem o trabalho concluído ao professor ou colegas. Basta carregar o modelo nos servidores cloud gratuitos do Google e copiar o URL gerado. Não são necessárias competências de programação!
- **Descarregar o modelo:** Escolha esta opção se quiser guardar os ficheiros do modelo localmente ou usá-los em ambientes baseados em tiles, como mBlock ou Scratch (através de extensões).
- **Excertos de código (JavaScript/p5.js):** Ideal para aulas avançadas de Ciência da Computação ou TI, onde os estudantes estão a construir aplicações web personalizadas e querem incorporar o seu modelo de IA em código web real.

- **Navegação e controlos:** Em todo o espaço de trabalho da Máquina Ensino, vários elementos e controlos de navegação ajudarão a mover-se entre secções e a executar ações. Estes podem incluir:
    - Botões e links: para navegar entre diferentes áreas da plataforma ou iniciar ações.
    - Menus: Para aceder a definições, opções ou recursos de ajuda.
    - Rótulos e instruções: para o guiar durante o processo e fornecer informações úteis. Embora o espaço de trabalho do Teachable Machine seja concebido para ser intuitivo, é sempre uma boa ideia explorar a interface e familiarizar-se com as suas diferentes secções e controlos antes de iniciar um projeto.




A Teachable Machine utiliza um fluxo de trabalho fácil de seguir que os professores podem usar como modelo durante as aulas. Este ciclo ajuda os alunos a visualizar como os sistemas de IA aprendem e melhoram.




Cada fase pode tornar-se uma mini-lição: a recolha de dados ensina ética e precisão; a formação desenvolve paciência e observação; a avaliação incentiva a reflexão e o trabalho em equipa.

# Módulo 3: Criação de Projetos de Imagem

Antes de começar a criar o seu primeiro projeto de imagem no Teachable Machine, é essencial estabelecer uma base sólida através de um planeamento e preparação cuidadosos. Este módulo guia-o pelos passos iniciais para definir o seu projeto, identificar aplicações adequadas e estabelecer critérios claros de sucesso.

## 3.1 Planeamento de projetos: Definir a sua IA baseada em imagens

### 3.1.1 Identificar aplicações em sala de aula para reconhecimento de imagens

O reconhecimento de imagens, impulsionado por aprendizagem automática, oferece uma multiplicidade de possibilidades entusiasmantes para transformar o ensino e a aprendizagem na sala de aula. Esta tecnologia pode criar experiências de aprendizagem interativas, automatizar

tarefas e proporcionar aos alunos novas formas de explorar e compreender o mundo à sua volta. Aqui estão alguns exemplos de aplicações do reconhecimento de imagens na sala de aula:

- **Identificação e classificação de objetos:** O reconhecimento de imagens revela-se útil para criar ferramentas que ajudam os alunos a identificar e classificar objetos em imagens. Esta aplicação é particularmente valiosa em áreas como ciências, onde os alunos podem construir modelos para reconhecer diferentes tipos de plantas, animais, rochas ou células. Por exemplo, os alunos podem desenvolver um projeto para identificar diferentes espécies de árvores com base em imagens das suas folhas, ou classificar vários tipos de nuvens a partir de fotografias meteorológicas. Esta atividade melhora as capacidades de observação, pensamento crítico e compreensão do mundo natural dos alunos.
- **Quizzes e jogos baseados em imagens:** Integrar o reconhecimento de imagens em questionários e jogos interativos torna a aprendizagem mais envolvente e agradável. Os professores, por exemplo, podem criar um questionário em que os alunos identificam figuras históricas a partir de retratos, ou um jogo em que associam imagens de marcos famosos aos seus nomes. Este tipo de aplicação oferece feedback imediato aos alunos, tornando a aprendizagem interativa e divertida.
- **Tecnologias assistivas:** O reconhecimento de imagem pode ser usado para desenvolver tecnologias assistivas para alunos com deficiências. Um projeto, por exemplo, pode ajudar alunos com deficiência visual a identificar objetos no seu ambiente, ou ajudar alunos com dificuldades de aprendizagem a reconhecer e classificar diferentes símbolos ou ícones. Esta aplicação promove a inclusão e oferece apoio personalizado aos alunos.
- **Projetos de arte e design:** Explore aplicações criativas em arte e design usando reconhecimento de imagem. Os alunos podem criar um projeto que reconheça diferentes estilos artísticos ou artistas, ou um que gere obras baseadas em imagens reconhecidas. Isto promove a criatividade, a inovação e a apreciação pela arte e pelo design.
- **Melhorar as experiências científicas:** O reconhecimento de imagens pode automatizar a recolha e análise de dados em experiências científicas. Os estudantes, por exemplo, poderiam criar um projeto que conte automaticamente objetos numa imagem, ou que meça o crescimento das plantas ao longo do tempo com base na análise da imagem. Esta aplicação poupa tempo e melhora a precisão das investigações científicas.
- **Apoio à aprendizagem de línguas:** Podem ser desenvolvidas ferramentas para ajudar os aprendentes a aprender novas línguas usando reconhecimento de imagens. Por exemplo, os alunos podem criar um projeto que reconheça objetos e exiba os seus nomes em diferentes línguas, ou um projeto que ajude na leitura ao reconhecer letras e palavras em imagens. Isto torna a aprendizagem de línguas mais visual e interativa.

Estes exemplos representam apenas algumas das muitas aplicações do reconhecimento de imagem na sala de aula. As possibilidades são vastas, limitadas apenas pela criatividade e engenho dos educadores e alunos.

### 3.1.2 Escolha de objetos ou conceitos adequados para classificação

Selecionar os objetos ou conceitos certos para o seu Projeto de Imagem é crucial para garantir o seu sucesso e valor educativo. As suas escolhas influenciam diretamente a complexidade do projeto, a viabilidade da recolha de dados e a sua relevância para os seus objetivos de aprendizagem. Aqui estão algumas considerações-chave para escolher objetos ou conceitos adequados para classificação na Teachable Machine:

- **Simplicidade e distintividade:** Comece com objetos ou conceitos que sejam visualmente distintos e fáceis de diferenciar. Evite categorias demasiado semelhantes ou com diferenças subtis, pois estas podem ser difíceis de aprender para o modelo. Por exemplo, em vez de tentar classificar vários tipos de nuvens (o que pode ser desafiante devido às suas formas e aparências variadas), comece por algo mais simples, como classificar imagens de fruta (por exemplo, maçãs, bananas, laranjas), onde as diferenças visuais são mais pronunciadas. À medida que os alunos ganham experiência, podem gradualmente avançar para tarefas de classificação mais complexas.
- **Relevância para os objetivos de aprendizagem:** Escolha objetos ou conceitos que estejam diretamente alinhados com os seus objetivos específicos de aprendizagem e objetivos curriculares. Selecione categorias que ajudem os alunos a adquirir novas informações, desenvolver competências específicas ou explorar tópicos relevantes. Por exemplo, numa aula de ciências das plantas, os alunos podem criar um projeto para classificar diferentes tipos de folhas ou flores. Se estiver a dar uma aula de história, os alunos podem criar um projeto para identificar vários artefactos históricos ou marcos históricos. Certifique-se de que o projeto apoia e enriquece a experiência global de aprendizagem.
- **Viabilidade da recolha de dados:** Considere a facilidade e praticidade de recolher dados suficientes para os objetos ou conceitos que escolhe. Selecione categorias para as quais possa obter facilmente um conjunto de dados diverso e representativo. Se quiser captar imagens usando uma webcam, escolha objetos que sejam facilmente acessíveis e fotografáveis na sua sala de aula ou ambiente de aprendizagem. Se utilizar imagens existentes, assegure o acesso a uma coleção adequada online ou de outros recursos. Evite categorias difíceis de captar ou que exijam equipamentos ou ambientes especializados.
- **Clareza das categorias:** Defina categorias claras e inequívocas para o seu projeto. Certifique-se de que existe sobreposição ou ambiguidade mínima entre estas categorias.

Cada categoria deve representar um objeto ou conceito distinto e bem definido. Evite categorias demasiado amplas ou que possam ser facilmente confundidas entre si. Por exemplo, em vez de categorias amplas como 'animais' e 'animais de estimação', opte por categorias separadas como 'gatos', 'cães' e 'pássaros'.

- **Envolvimento e interesse dos alunos:** Escolha objetos ou conceitos que provavelmente vão despertar o interesse dos seus alunos. Selecione categorias que sejam relevantes para as suas vidas, hobbies ou interesses. O interesse dos alunos num projeto traduz-se frequentemente em maior motivação para participação e aprendizagem. Considere envolver os alunos no processo de seleção, proporcionar uma chuva de ideias em conjunto e permitir que escolham categorias apelativas.
- **Considerações éticas:** Tenha sempre em conta quaisquer considerações éticas relacionadas com os objetos ou conceitos que escolher. Evite categorias que possam ser ofensivas, discriminatórias ou prejudiciais. Se estiver a trabalhar com imagens de pessoas, certifique-se de que o consentimento adequado é obtido e que a privacidade é protegida. Escolha categorias que promovam valores positivos e o uso responsável da tecnologia.

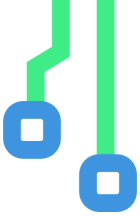
Ao considerar cuidadosamente estes fatores, selecione objetos ou conceitos adequados para os seus Projetos de Reconhecimento Automático de Imagens, garantindo que são educativos valiosos, envolventes e eticamente corretos.

### 3.1.3 Definição dos critérios de sucesso do projeto

Estabelecer critérios claros de sucesso antes de iniciar o seu projeto de imagem com a Teachable Machine é crucial para avaliar a sua eficácia e determinar se atingiu o objetivo pretendido. Os critérios de sucesso fornecem um parâmetro para medir o desempenho do seu projeto e identificar áreas a melhorar. Também o ajudam a manter o foco durante o processo de desenvolvimento e a garantir que se mantém no caminho certo para alcançar os seus objetivos. Aqui está um guia para definir critérios eficazes de sucesso no projeto:

- **Precisão e métricas de desempenho:** Definir objetivos para a precisão e desempenho do seu modelo de reconhecimento de imagem é uma forma comum de definir o sucesso.
    - **Precisão global:** Determinar a percentagem mínima aceitável de classificações corretas. Por exemplo, um objetivo pode ser alcançar 90% de precisão global, o que significa que o modelo classifica corretamente 90% das imagens que lhe são apresentadas.
    - **Precisão específica de cada classe:** Para classes mais importantes ou desafiantes, podem ser definidas metas específicas de precisão para cada uma. Por

exemplo, pode ser necessária maior precisão para identificar objetos críticos num projeto de diagnóstico médico.
    - **Precisão e recordação (simplificado):** Estas métricas dão-lhe uma compreensão mais detalhada de quão bem o seu modelo está a funcionar. A precisão indica com que frequência o modelo estava certo quando dizia que algo pertencia a uma determinada classe. Recorde com que frequência o modelo identificou corretamente algo que *realmente* pertencia a uma determinada classe. Um modelo equilibrado normalmente tem um bom desempenho em ambos os aspetos.
    - **Tempo de resposta:** Se for necessário reconhecimento de imagem em tempo real, defina um valor-alvo para o tempo máximo aceitável de resposta. Isto mede o tempo que o modelo demora a processar uma imagem e fornece uma classificação.
- **Funcionalidade e usabilidade:** Defina critérios relacionados com a funcionalidade e usabilidade do seu projeto, especialmente se este tiver como alvo uma aplicação ou grupo de utilizadores específico.
    - **Facilidade de utilização:** Se o seu projeto inclui uma interface de utilizador, devem ser definidos critérios quanto à sua facilidade de utilização e intuitividade. Considere se os utilizadores conseguem interagir facilmente com o modelo e compreender os seus resultados.
    - **Integração:** Para projetos destinados à integração com outro sistema ou aplicação, defina critérios para uma integração bem-sucedida. Certifique-se de que o modelo se liga e troca dados com o outro sistema de forma fluida.
    - **Acessibilidade:** Se o seu projeto se destina a um grupo diversificado de utilizadores, estabeleça critérios relativamente à sua acessibilidade. É utilizável por pessoas com deficiência?
- **Impacto educativo (se aplicável):** Para projetos concebidos para fins educativos, definam critérios relacionados com o seu impacto na aprendizagem dos alunos.
    - **Resultados de aprendizagem:** O projeto ajuda os aprendentes a alcançar os resultados de aprendizagem desejados? Os alunos conseguem demonstrar um aumento de conhecimentos ou competências após utilizarem o projeto?
    - **Envolvimento:** O projeto envolve os alunos e motiva-os a aprender? Os alunos acham o projeto interessante e agradável?
    - **Feedback dos alunos:** Recolha feedback dos alunos sobre a sua experiência com o projeto. Acham útil, informativo ou agradável?
- **Requisitos técnicos:** Defina critérios relacionados com quaisquer requisitos técnicos específicos do seu projeto.
    - **Compatibilidade de plataformas:** O projeto funciona corretamente nas plataformas ou dispositivos pretendidos?



    - **Utilização de recursos:** O projeto utiliza os recursos de forma eficiente? Corre de forma fluida sem consumir excesso de poder de processamento ou memória?
- **Considerações éticas:** Incorpore considerações éticas nos seus critérios de sucesso.
    - **Mitigação do preconceito:** O projeto demonstra imparcialidade e minimiza o viés nas suas previsões?
    - **Proteção da privacidade:** O projeto protege a privacidade dos utilizadores e gere os dados de forma responsável?

Exemplos de critérios de sucesso:

- "O modelo de reconhecimento de imagem atinge uma precisão global de 92% na classificação de imagens de diferentes tipos de folhas."
- "Os alunos que utilizam o questionário baseado em imagens demonstram uma melhoria de 20% no seu conhecimento de figuras históricas."
- "O projeto de tecnologia assistiva identifica corretamente 95% dos objetos domésticos comuns e fornece descrições áudio claras ao utilizador."
- "O modelo de reconhecimento de imagem integra-se perfeitamente no sistema de gestão de inventário existente e reduz o tempo de processamento em 15%."

Ao definir critérios de sucesso claros, mensuráveis e relevantes, orienta eficazmente o desenvolvimento do seu projeto de imagem Teachable Machine e assegura que cumpre os seus objetivos pretendidos.

## 3.2 Recolha e preparação de dados: Construir o seu conjunto de dados

Os dados são o motor de qualquer modelo de Aprendizagem Automática. A qualidade, quantidade e diversidade dos seus dados têm um impacto direto no desempenho e na precisão do seu projeto Teachable Machine. Por isso, planear uma estratégia robusta de recolha de dados é essencial para construir um modelo bem-sucedido.

### 3.2.1 Recolha de dados de imagens: fontes e métodos

A qualidade e diversidade do seu conjunto de dados de imagens é fundamental para o sucesso do seu projeto de imagem na Teachable Machine. Um conjunto de dados bem construído permite que o seu modelo aprenda eficazmente e faça previsões precisas. Esta secção descreve várias fontes e métodos para recolher dados de imagens:

- **Captura por webcam:** O Teachable Machine oferece uma funcionalidade prática que permite captar imagens diretamente usando a webcam do seu computador. Este método

revela-se particularmente útil para recolher imagens de objetos facilmente disponíveis no seu ambiente imediato.

- **Vantagens:**
  - A recolha de dados é fácil e rápida.
  - É possível a captura em tempo real de objetos ou cenas específicas.
  - Podes controlar a iluminação, o fundo e o ângulo da imagem.
- **Considerações:**
  - Podem existir limitações relacionadas com a disponibilidade de objetos ou do ambiente.
  - A qualidade da imagem pode depender da resolução da webcam e das condições de iluminação.

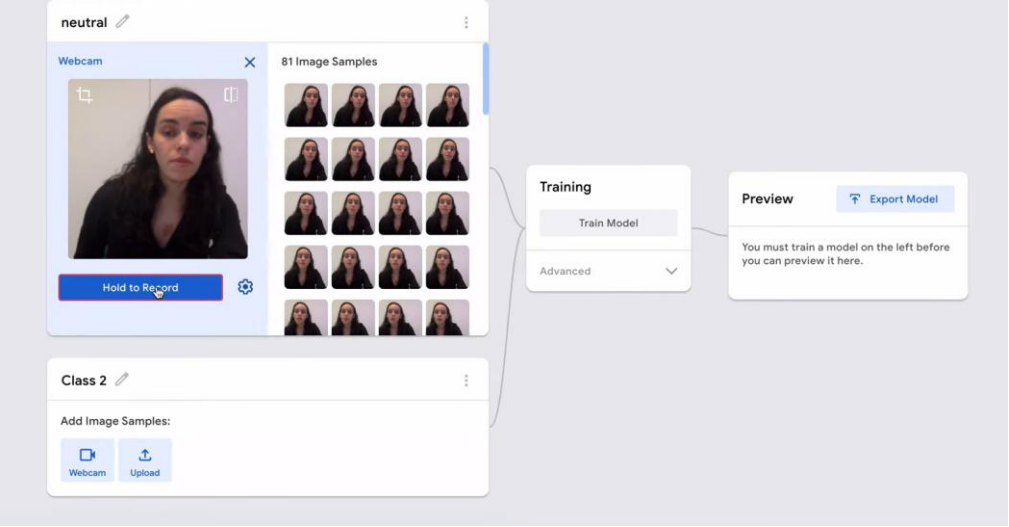



Imagem 8: Captura por webcam

- **Bibliotecas e bases de dados de imagens existentes: Existem** inúmeras bibliotecas de imagens e bases de dados online que oferecem vastas coleções de imagens adequadas para os seus projetos com a Teachable Machine. Estes recursos são particularmente úteis para aceder a imagens de objetos ou conceitos que não são facilmente captados com uma webcam.
  - **Exemplos de funcionalidades:**
    - Unsplash: Disponibiliza uma coleção de imagens de alta resolução que são gratuitas de uso.
    - Pexels: Oferece uma coleção semelhante de imagens e vídeos gratuitos.
    - Google Imagens: Pode ser usado para pesquisar imagens específicas, mas esteja atento às restrições de direitos de autor.

        - Bases de dados especializadas: Dependendo do seu projeto, podem estar disponíveis bases de dados especializadas (por exemplo, bases de dados de imagem médica, bases de dados de plantas).
    - **Vantagens:**
        - O acesso a uma grande variedade de imagens é garantido.
        - Poupa tempo e esforço comparado com capturar todas as imagens sozinho.
        - É concedido acesso a imagens de objetos ou conceitos que, de outra forma, seriam difíceis de obter.
    - **Considerações:**
        - Por favor, note restrições de direitos de autor e direitos de utilização.
        - A qualidade e consistência da imagem podem variar.
        - Uma filtragem cuidadosa ou seleção das imagens garante a sua relevância para o seu projeto.
- **Coleções fotográficas pessoais:** Se tiver uma coleção pessoal, algumas imagens podem ser utilizáveis para o seu projeto Teachable Machine. Esta pode ser uma boa opção para recolher imagens de objetos ou cenas familiares.
    - **Vantagens:**
        - Acesso fácil a uma coleção de imagens existente.
        - As imagens provavelmente serão relevantes para o teu contexto.
        - Um toque pessoal é acrescentado ao seu projeto.
    - **Considerações:**
        - Certifique-se de que tem o direito de usar as imagens.
        - A qualidade e consistência da imagem podem variar.
        - Uma seleção cuidadosa das imagens garante a adequação para o seu projeto.

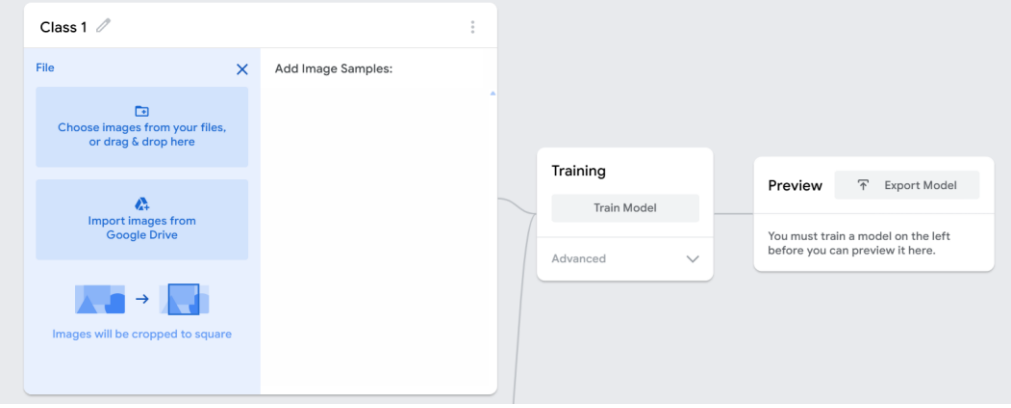



Imagem 9: Imagens existentes/a carregar fotos pessoais

- **Aumento de Imagens:** Esta técnica envolve aumentar artificialmente o tamanho e a diversidade do seu conjunto de dados aplicando várias transformações a imagens existentes. Este pode ser um método valioso para melhorar o desempenho do seu modelo.
    - **Exemplos de técnicas de aumento:**
        - Rodar imagens.
        - Vira as imagens horizontal ou verticalmente.
        - Recorte de imagens.
        - Aproxima ou afasta as imagens.
        - Ajusta o brilho ou contraste da imagem.
    - **Vantagens:**
        - Isto aumenta o tamanho e a diversidade do seu conjunto de dados.
        - Pode melhorar a capacidade do seu modelo de generalizar e lidar com variações nas imagens.
        - Ajuda a evitar o sobreajuste (quando o modelo aprende demasiado bem os dados de treino e tem um desempenho fraco com dados novos).
    - **Considerações:**
        - Use as técnicas de aumento com discernimento.
        - Certifique-se de que as transformações são realistas e não alteram significativamente o conteúdo da imagem.

Ao recolher dados de imagens, é fundamental priorizar a qualidade, diversidade e relevância. Certifique-se de que as suas imagens são nítidas, focadas e representativas dos objetos ou conceitos que o seu modelo deve reconhecer.

💡 Dica profissional

**Maior precisão (qualidade vs. quantidade):** Qualidade e variedade são muito mais importantes do que o simples volume. Em vez de capturar 100 fotografias idênticas de um objeto exatamente no mesmo local, tire 30 fotos de diferentes ângulos, a distâncias variadas e sob condições de iluminação distintas. Por exemplo, se estiver a treinar a IA para reconhecer uma maçã, inclua fotos de maçãs vermelhas, verdes e até maçãs meio comidas, para que o modelo aprenda o conceito verdadeiro, em vez de uma única imagem específica!

**Foco conceptual para os alunos:** Enfatize aos seus alunos que os computadores não "veem" verdadeiramente imagens como os humanos. Em vez disso, o modelo converte imagens em matrizes numéricas de píxeis e deteta diferenças matemáticas entre cores, texturas e formas geométricas para inferir previsões.

### 3.2.2 Criação de Classes de Imagem: Definindo Categorias para o Seu Modelo

No Teachable Machine, as "classes" representam as categorias ou rótulos distintos que o seu modelo de reconhecimento de imagem aprende a identificar. Definir estas classes de forma clara e precisa é um passo crucial na preparação do seu conjunto de dados e na garantia de que o seu modelo distingue eficazmente entre diferentes objetos ou conceitos. Aqui está um guia para criar classes de imagem:

- **Defina claramente as suas categorias:** Antes de adicionar imagens, dedique algum tempo a definir cuidadosamente as categorias que o seu modelo irá reconhecer. Cada classe deve representar um objeto, conceito ou classificação específico que seja relevante para os objetivos do seu projeto. Certifique-se de que as categorias são bem definidas, inequívocas e mutuamente exclusivas (tanto quanto possível). Isto significa que não deve haver sobreposição ou confusão mínima entre categorias. Por exemplo, ao classificar fruta, as classes podem ser "maçã", "banana", "laranja" e "uva".
- **Determine o número de classes:** O número de classes de que precisa depende da complexidade do seu projeto e do número de objetos ou conceitos distintos a reconhecer. Comece com um número razoável, especialmente se for principiante. Pode sempre adicionar mais classes mais tarde, se necessário. Considere o compromisso entre o número de classes e os dados de que precisa; mais classes geralmente exigem mais dados para um treino eficaz de modelos.
- **Dê às suas turmas nomes  apropriados:** Atribua nomes claros e descritivos às turmas, que reflitam com precisão os objetos ou conceitos que representam. Isto ajuda na organização e garante uma compreensão fácil do propósito de cada classe. Use convenções de nomenclatura consistentes, por exemplo, substantivos singulares (por exemplo, "maçã" em vez de "maçãs") ou termos específicos (por exemplo, "maçã vermelha" em vez de apenas "maçã").

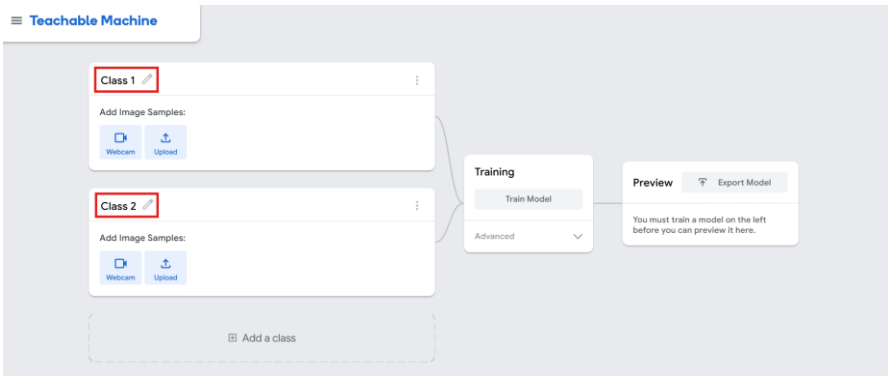



Imagem 10: Definição dos Nomes das Turmas

- **Crie classes na Teachable Machine:** A Teachable Machine oferece uma interface intuitiva para criar e gerir classes. Existe uma área disponível para adicionar novas classes, renomear as existentes ou eliminar classes. Siga as instruções no ecrã para criar as suas turmas e de-lhes nomes apropriados.

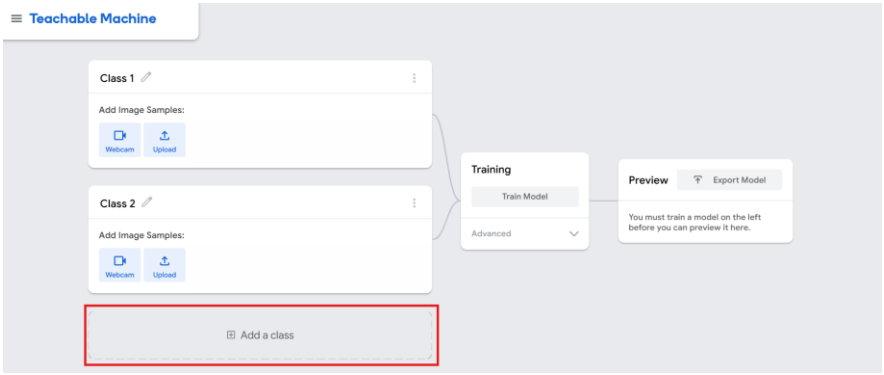



Imagem 11: Adicionar Novas Turmas

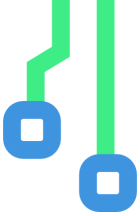
- **Considere a classificação hierárquica (se aplicável):** Em alguns casos, um sistema de classificação hierárquica pode ser desejável, com categorias e subcategorias mais amplas. Por exemplo, ao classificar animais, pode ter "mamíferos", "aves" e "répteis" como classes mais amplas, e depois subcategorias como "cão", "gato" e "vaca" dentro de "mamíferos". Embora a Teachable Machine possa não suportar diretamente a classificação hierárquica, um efeito semelhante pode ser alcançado criando classes mais específicas.
- **Revise e aperfeiçoe as suas aulas:** Depois de criar o seu conjunto inicial de aulas, reveja-as cuidadosamente para garantir que são adequadas aos objetivos do seu projeto. Considere se precisa de adicionar, remover ou renomear classes. Muitas vezes, refinar classes torna-se útil depois de começar a recolha de dados, à medida que adquire uma melhor compreensão das variações dos dados.

Ao definir e criar cuidadosamente as suas classes de imagens, estabelece uma base sólida para o design da sua imagem no Teachable Machine, garantindo que o seu modelo aprende eficazmente a distingue entre categorias específicas.

### 3.2.3 Aumento de Dados: Melhorar o Seu Conjunto de Dados

A ampliação de dados é uma técnica poderosa para aumentar artificialmente o tamanho e a diversidade do seu conjunto de dados de imagens. Isto envolve aplicar várias transformações a imagens existentes para criar novas versões ligeiramente modificadas. Este método pode melhorar significativamente a robustez e a generalização do seu projeto de imagem Teachable Machine, ajudando-o a ter um bom desempenho com dados nunca antes vistos. Aqui está um guia sobre aumento de dados:

- **Por que usar aumento de dados?**
  - **Aumento do tamanho do conjunto de dados:** Aumentar permite gerar mais dados de treino a partir de imagens existentes, expandindo efetivamente o seu conjunto de dados sem necessidade de recolher novas imagens. Isto é particularmente útil quando as imagens originais são limitadas.
  - **Melhor generalização:** Ao introduzir variações nos seus dados de treino, a ampliação ajuda o modelo a aprender características mais robustas e a tornar-se menos sensível a detalhes específicos nas imagens de treino. Isto melhora a capacidade do modelo de generalizar para imagens novas, nunca antes vistas, que podem diferir ligeiramente dos dados de treino.
  - **Redução do sobreajuste:** O sobreajuste ocorre quando um modelo aprende demasiado bem os dados de treino, incluindo o ruído e as suas peculiaridades, o que leva a um desempenho fraco em novos dados. O aumento ajuda a prevenir o sobreajuste ao tornar o modelo menos dependente de exemplos específicos de treino e incentivá-lo a aprender características mais generalizáveis.
- **Técnicas comuns de aumento:**
  - **Rotação:** Rodar imagens em vários ângulos (por exemplo, 10, 45, 90 graus) ajuda o modelo a reconhecer objetos independentemente da sua orientação.
  - **Invertimento:** Inverter imagens horizontal ou verticalmente ajuda o modelo a reconhecer objetos, mesmo que estejam espelhados.
  - **Recorte:** Recortar aleatoriamente partes das imagens ajuda o modelo a focar-se em diferentes partes de um objeto, tornando-o menos sensível à composição global da imagem.
  - **Zoom/Zoom Out:** Ampliar ou reduzir imagens permite ao modelo aprender a reconhecer objetos em diferentes escalas.
  - **Ajustes de brilho e contraste:** A variação do brilho e contraste da imagem ajuda o modelo a tornar-se mais robusto em diferentes condições de iluminação.



- **Variação de Cor:** Ajustar aleatoriamente as propriedades de cor da imagem (por exemplo, matiz, saturação) ajuda o modelo a tornar-se menos sensível às variações de cor.
- **Adicionar ruído:** Introduzir ruído aleatório nas imagens aumenta a robustez do modelo perante dados ruidosos ou imperfeitos.

- **Aplicação de Aumento de Dados:**
  - **Funcionalidades integradas da Teachable Machine:** A Teachable Machine inclui algumas funcionalidades básicas de aumento de dados integradas. Explore as opções da plataforma para aplicar transformações simples, como inverter ou recortar, diretamente na interface.
  - **Ferramentas e bibliotecas externas (para exploração avançada):** Para técnicas de ampliação mais avançadas, software externo de edição de imagem (por exemplo, GIMP, Photoshop) ou bibliotecas de programação (como o `ImageDataGenerator` do Python, TensorFlow/Keras ou `albumentas`) podem ser usados para aplicar programáticamente várias transformações. Para professores do ensino básico, normalmente basta focar-se nas funcionalidades incorporadas; estas ferramentas externas destinam-se a uma exploração posterior.
- **Melhores Práticas de Aumento:**
  - Aplique as técnicas de ampliação com sabedoria. Evite ampliar demasiado os dados ao ponto de as imagens transformadas deixarem de se assemelhar a variações realistas dos originais.
  - Tenha em conta os requisitos específicos do seu projeto e escolha técnicas de aumento relevantes para as variações que o seu modelo provavelmente irá encontrar.
  - Acompanhe o desempenho do seu modelo num conjunto de validação (dados não usados para treino) para garantir que o aumento melhora a generalização e não prejudica o desempenho.

Ao utilizar eficazmente a ampliação de dados, melhora a robustez, precisão e generalização dos seus designs de imagens com a Teachable Machine, levando a modelos de reconhecimento de imagem mais fiáveis e eficazes.

### 3.2.4 Prepare os Seus Dados para a Máquina Aprendível

Depois de recolher os dados das suas imagens e aplicar as técnicas de aumento desejadas, o passo seguinte é prepará-los para uso no Teachable Machine. A preparação adequada dos dados garante que as suas imagens estão no formato correto, organizadas de forma eficaz e prontas para treinar o seu modelo de ML. Aqui está um guia para preparar os seus dados:

- **Formatos de ficheiro de imagem:** O Teachable Machine normalmente suporta formatos comuns de ficheiro de imagem, tais como:
    - JPEG (.jpg ou .jpeg)
    - PNG (.png)
    - GIF (.gif) Certifique-se de que as suas imagens são guardadas num destes formatos. Se forem usados outros formatos, pode ser necessária conversão através de software de edição de imagem ou ferramentas online.
- **Resolução e tamanho da imagem:** Embora o Teachable Machine suporte várias resoluções de imagem, é geralmente recomendado usar imagens com dimensões adequadas ao seu projeto. Imagens com resolução muito elevada consomem mais poder de processamento, o que pode atrasar o treino. Por outro lado, imagens com resolução muito baixa podem não ter detalhe suficiente para uma aprendizagem eficaz de modelos. Considere redimensionar imagens para um tamanho razoável antes de as carregar para o Teachable Machine. Um intervalo comum situa-se entre 224x224 e 512x512 píxeis, embora o tamanho ideal dependa da complexidade do projeto. É vantajoso manter consistência no tamanho das imagens em todo o seu conjunto de dados.
- **Organização de dados:** Organize os seus ficheiros de imagem em pastas correspondentes às classes definidas no Teachable Machine. Crie uma pasta separada para cada classe e coloque as imagens relevantes nessa pasta. Esta estrutura de pastas facilita o carregamento de dados no Teachable Machine, pois pastas inteiras geralmente podem ser carregadas de uma só vez. Use convenções de nomenclatura claras e consistentes para os seus ficheiros de imagem para garantir uma organização lógica.
- **Limpeza de dados:** Antes de carregar, reserve algum tempo para rever e limpar o seu conjunto de dados de imagens. Remova quaisquer ficheiros de imagem irrelevantes, inadequados, corrompidos ou danificados. Se necessário, edite as imagens para melhorar a qualidade ou consistência (por exemplo, corte, ajuste o brilho).
- **Divisão de Dados (opcional, mas recomendado):** Para práticas mais avançadas de Aprendizagem Automática, recomenda-se dividir o seu conjunto de dados em três subconjuntos:
    - **Conjunto de treino:** O maior subconjunto, usado para treinar o modelo de ML.
    - **Conjunto de validação:** Usado para avaliar o desempenho do modelo durante o treino e ajustar os hiperparâmetros.
    - **Conjunto de teste:** Usado para avaliar o desempenho do modelo final após a conclusão do treino. O Teachable Machine não requer divisão explícita para uso básico, mas é uma boa prática para avaliação rigorosa do modelo. Obtém-se um efeito semelhante ao reservar uma parte dos seus dados e não a usar durante a fase

inicial de treino. Se optar por dividir os dados, certifique-se de que a distribuição das classes é semelhante entre todos os subconjuntos.

- **Carregar dados para a Teachable Machine:** Assim que os seus dados estiverem preparados, estão prontos para serem carregados na Teachable Machine. A plataforma oferece ferramentas intuitivas para carregar imagens, permitindo-lhe tipicamente:
    - Carregue imagens individualmente.
    - Carrega pastas inteiras de imagens.
    - Use a sua webcam para captar imagens diretamente. Siga as instruções no ecrã para carregar os seus dados e associá-los às classes corretas.

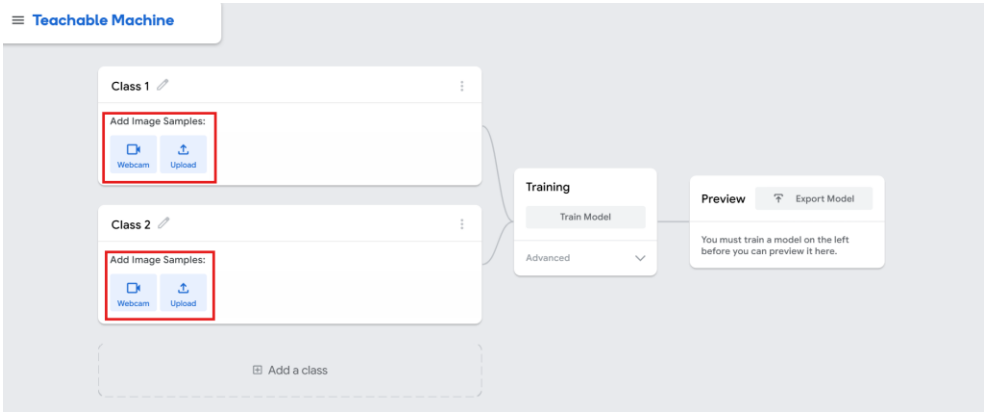



Imagem 12: Carregar Dados

Ao preparar cuidadosamente os seus dados, garante que estão nas condições ideais para treinar o seu projeto de imagem no Teachable Machine, levando a um melhor desempenho do modelo e resultados mais fiáveis.

## 3.3 Treino e Avaliação de Modelos: Dar Vida à Sua IA

### 3.3.1 Treinar o seu modelo de imagem: passo a passo

Depois de preparar o seu conjunto de dados de imagens, o passo seguinte é treinar o seu modelo de Aprendizagem Automática no Teachable Machine. O processo de treino envolve alimentar o modelo com os seus dados, permitindo-lhe aprender e reconhecer os padrões e características que distinguem as diferentes classes que definiu. O Teachable Machine simplifica este processo, tornando-o acessível mesmo para quem não tem experiência em programação. Aqui está um guia passo a passo para treinar o seu modelo de imagem:

- **Vai ao teu projeto:** Abrir Máquina Ensinable e vai ao projeto de imagem em que tens trabalhado. Certifica-te de que os teus dados de imagem estão carregados e organizados nas classes corretas.

- **Revise os seus dados:** Antes de iniciar o processo de formação, reserve um momento para rever os seus dados. Confirme a sua precisão e certifique-se de que cada aula contém um número suficiente de imagens representativas. Normalmente, pode percorrer as imagens de cada aula diretamente na interface Teachable Machine.
- **Iniciar o treino:** A Teachable Machine fornece um botão ou comando claro para iniciar o processo de treino. Este é um botão claramente visível que diz "Modelo de Treino". Clique neste botão para iniciar o treino.

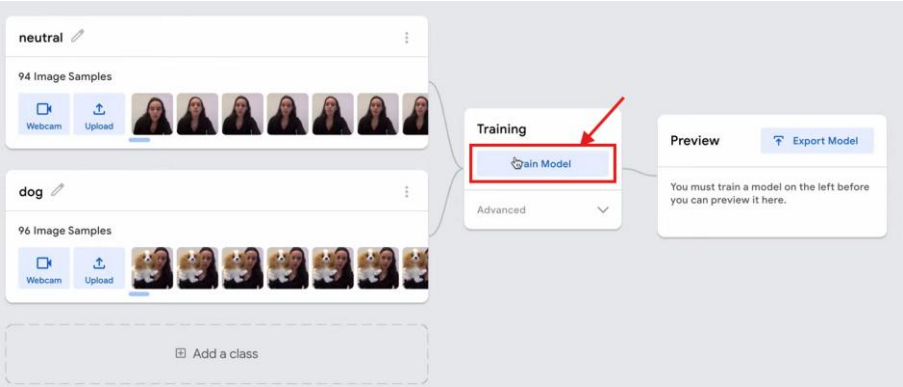



Imagem 12: Começar o treino.

- **Processo de treino:** Assim que inicia o treino, a Teachable Machine começa a processar os seus dados de imagem. A plataforma utiliza algoritmos de Aprendizagem Automática para analisar imagens e identificar características-chave que distinguem as classes. Durante o treino, o modelo ajusta os seus parâmetros internos para otimizar a sua capacidade de classificar corretamente as imagens. A Teachable Machine fornece feedback visual sobre o progresso do treino. Isto inclui barras de progresso, mensagens ou animações que indicam que o treino está em curso. A duração do processo de treino depende do tamanho e complexidade do seu conjunto de dados, bem como do poder de processamento do seu computador ou dos servidores da plataforma.

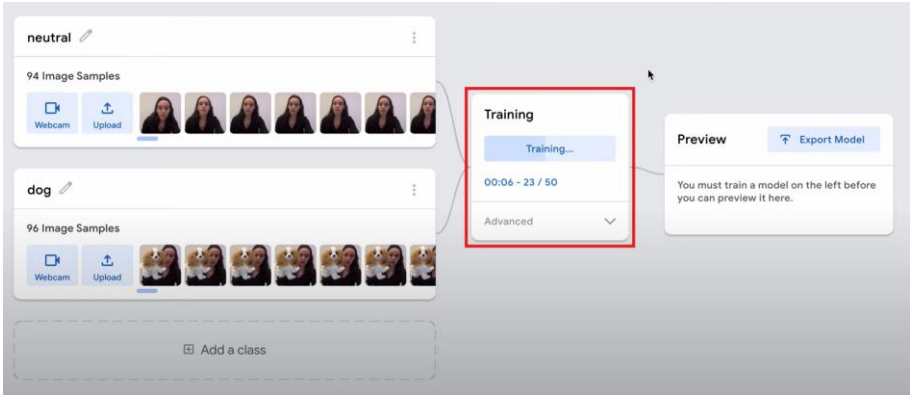


Imagem 13: Processo de formação.

- **Não é necessário programação:** Uma vantagem fundamental do Teachable Machine é a forma como lida com os cálculos complexos do treino de modelos em segundo plano. Não precisa de escrever código nem de ter conhecimento especializado de algoritmos de Machine Learning para treinar o seu modelo.
- **Definições Avançadas de Treino (opcionais para exploração adicional):** Embora tenha sido concebida para ser simples, a Teachable Machine oferece "Definições Avançadas" que permitem aos utilizadores afinar o processo de treino. Estas definições podem influenciar a forma como o modelo aprende e o seu desempenho final. A disponibilidade e a natureza específica destas definições podem variar ligeiramente com as atualizações da plataforma Teachable Machine.
    - **Estações:** Uma representa uma passagem completa por todo o conjunto de dados de treino durante o processo de treino. Aumentar o número de estações geralmente permite uma aprendizagem mais aprofundada, mas também aumenta o risco de sobreajuste (onde o modelo tem bom desempenho em dados de treino mas tem um desempenho fraco em dados novos). O Teachable Machine permite o ajuste das estações, dando-lhe controlo sobre a duração do treino.

💡 Analogia do professor:

Pensa nas temporadas como "rondas de treino". 50 temporadas significa que a IA analisa as tuas fotos de treino 50 vezes. Se a IA continuar a cometer erros durante a pré-visualização, tenta aumentar esta definição para 100 rondas.

    - **Tamanho do lote:** Isto refere-se ao número de amostras de dados (imagens, neste caso) que o modelo processa de cada vez durante cada atualização de parâmetro. Ajustar o tamanho do lote afeta a velocidade de treino e a dinâmica de aprendizagem. O Teachable Machine oferece opções para diferentes tamanhos de lote.
    - **Taxa de aprendizagem:** Um parâmetro crucial, a taxa de aprendizagem controla o tamanho do passo que o modelo realiza para atualizar os seus parâmetros com base no erro calculado (perda). Uma taxa de aprendizagem demasiado alta causa divergência e falha na aprendizagem, enquanto uma taxa demasiado baixa atrasa significativamente o processo de treino. Enquanto a Teachable Machine simplifica

muitos aspetos, fluxos de trabalho avançados de aprendizagem automática envolvem esta taxa. Se estiver disponível como opção, avance com cautela.

- **Outros hiperparâmetros:** Os modelos de aprendizagem automática têm parâmetros chamados hiperparâmetros que controlam o processo de aprendizagem. A Teachable Machine disponibiliza alguns destes parâmetros para ajuste. Ajustá-los frequentemente requer experimentação e compreensão dos princípios da aprendizagem automática.
- **Utilização de definições avançadas:** Se optar por usar definições avançadas, recomenda-se geralmente uma abordagem sistemática. Mude uma definição de cada vez, observe o seu impacto no desempenho do modelo e acompanhe meticulosamente cada experiência e resultados. A utilização eficaz requer frequentemente uma compreensão mais profunda dos conceitos de aprendizagem automática. Para quem é novo na aprendizagem automática, é aconselhável começar pelas definições pré-definidas e explorar gradualmente as opções avançadas à medida que ganha experiência.

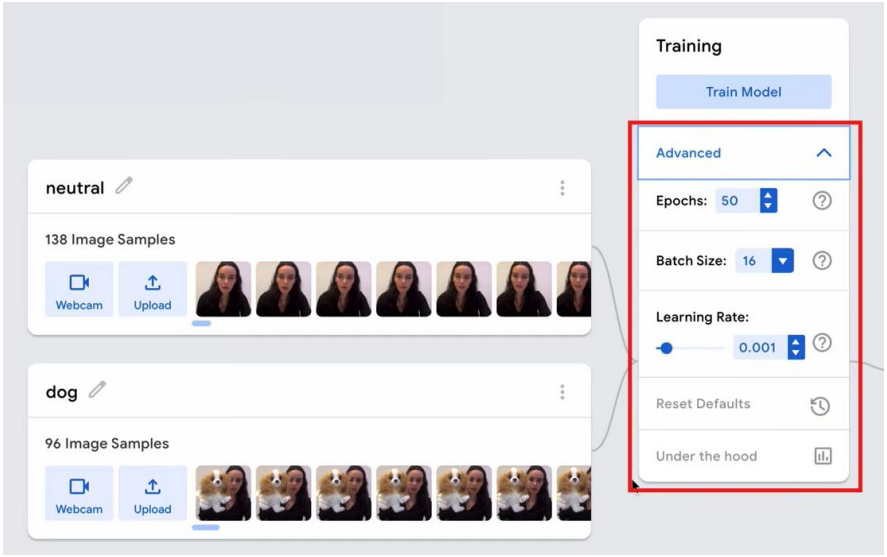



Imagem 14: Definições avançadas de treino.

- **Dicas de treino:**
  - **Comece com dados suficientes:** Certifique-se de que há dados adequados em cada turma antes do treino. Um conjunto de dados equilibrado, com um número razoável de imagens por turma, geralmente produz melhores resultados.
  - **Acompanhar o progresso (se disponível):** Se a Teachable Machine fornecer feedback sobre o progresso dos treinos, acompanhe-o para perceber como o modelo aprende.

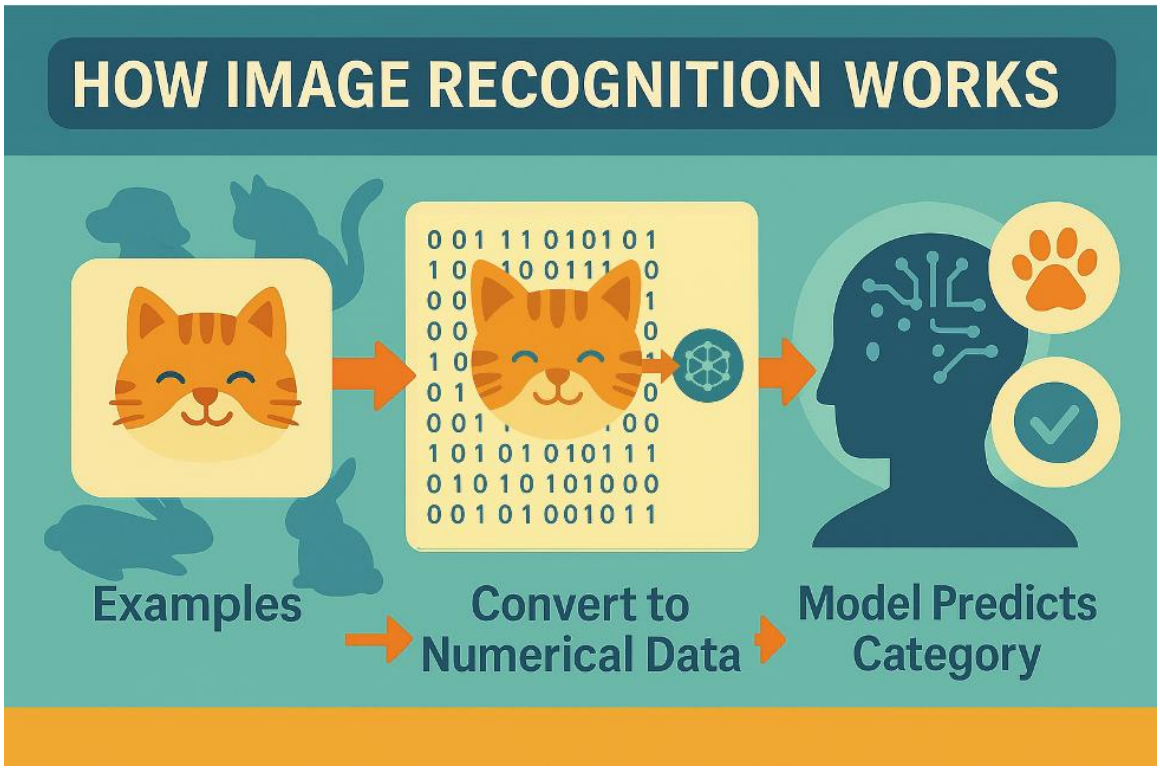
- **Treino iterativo:** Pode ser necessário treinar o modelo várias vezes, especialmente se os resultados iniciais forem insatisfatórios. Ajuste o seu conjunto de dados, adicione mais dados ou modifique classes e depois retreine o modelo.

- **Formação Concluída:** Assim que o processo de formação está concluído, a Teachable Machine notifica-o. O seu modelo de reconhecimento de imagem está agora treinado e pronto para avaliação e utilização.

A Teachable Machine simplifica o processo de treino, tornando-o acessível a uma vasta gama de utilizadores. Ao seguir estes passos e garantir um conjunto de dados bem preparado, treina eficazmente o seu modelo de imagem e começa a explorar as suas capacidades.

**Como Funciona o Reconhecimento de Imagens (Simplificado):**

A aprendizagem automática para imagens baseia-se em grandes conjuntos de exemplos. Cada imagem é convertida em dados numéricos (píxeis) que o modelo analisa para identificar padrões recorrentes. Após o treino, o modelo prevê a que categoria pertence uma nova imagem com base no que aprendeu.



| 🧠 Processo simplificado | | | | |
|---|---|---|---|---|
|  |  |  |  |  |
| 1. Cobrar Exemplos | 2. Comboio | 3. Avaliar | 4. Testar novos Imagens | 5. Melhorar com Feedback |

Os professores devem salientar que os computadores na verdade não 'veem' imagens, mas sim detetam diferenças matemáticas entre cores, texturas e formas.

### 3.3.2 Avaliação do Desempenho do Modelo: Compreensão da Precisão e Métricas

Depois de treinar o seu modelo de imagem na Teachable Machine, avaliar o seu desempenho é crucial para determinar se funciona bem e se cumpre os critérios de sucesso do seu projeto. A avaliação envolve testar o modelo com dados que não viu durante o treino e analisar as suas previsões. Aqui está um guia para avaliar o desempenho do modelo:

- **Teachable Machine Preview:** Uma funcionalidade de pré-visualização integrada no Teachable Machine permite-lhe testar rapidamente o seu modelo treinado. Pode usar a sua webcam para captar novas imagens ou carregar imagens existentes, e depois observar como o modelo as classifica. Esta pré-visualização oferece uma forma intuitiva de avaliar rapidamente o desempenho do seu modelo. Observe se o modelo identifica corretamente os objetos ou conceitos nas imagens fornecidas. Preste atenção a quaisquer erros de classificação ou casos em que o modelo pareça incerto.

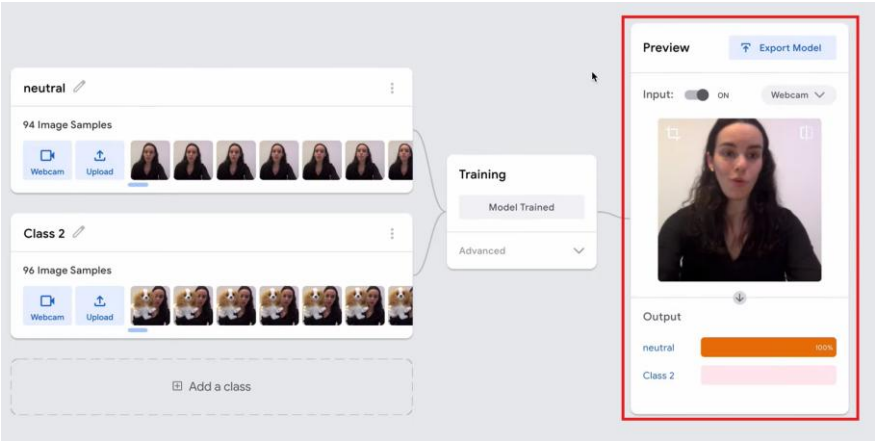


Imagem 15: Funcionalidade de pré-visualização.

- **Compreender a precisão:** A precisão é uma métrica comum para avaliar modelos de classificação. Representa a proporção global de previsões corretas feitas pelo modelo. Por exemplo, se fornecer ao modelo 100 imagens de teste e o modelo classificar corretamente 90, a precisão é de 90%. Embora a precisão seja uma métrica útil, é importante estar ciente das suas limitações, especialmente em conjuntos de dados desequilibrados (onde algumas classes têm significativamente mais dados do que outras).
- **Matriz de confusão:** Uma matriz de confusão fornece uma análise mais detalhada do desempenho do seu modelo. Esta tabela mostra o número de previsões corretas e incorretas para cada classe. As linhas normalmente representam as classes reais, enquanto as colunas representam as classes previstas. Analisar a matriz de confusão ajuda a identificar que classes o modelo tem dificuldade em distinguir e onde comete mais erros.
- **Precisão e recordação (simplificada):** Outras métricas importantes, precisão e recordação, dão-lhe uma compreensão mais aprofundada do desempenho do seu modelo, especialmente com conjuntos de dados desequilibrados.
    - **Precisão:** mede a proporção de identificações positivas que estavam realmente corretas. Responde à pergunta: "De todas as vezes em que o modelo indicou que era uma certa classe, quantas vezes acertou?"
    - **Recordação:** Mede a proporção de casos positivos reais que foram corretamente identificados pelo modelo. Responde à pergunta: "De todas as vezes em que foi *realmente* uma determinada classe, com que frequência o modelo a indicou?" Uma pontuação de precisão elevada indica que o modelo se destaca na prevenção de falsos positivos, enquanto uma pontuação elevada na recordação significa que é eficaz na identificação de todos os casos de uma determinada classe.
- **Pontuação F1 (simplificada):** A pontuação F1 combina precisão e recordação num único valor. Fornece uma medida equilibrada do desempenho de um modelo, especialmente quando existe um desequilíbrio entre classes. Geralmente, uma pontuação F1 mais alta indica melhor desempenho.
- **Melhores práticas de avaliação:**
    - **Use um conjunto de testes separado:** Para uma avaliação imparcial, é crucial testar o seu modelo com dados que não encontrou durante o treino. Isto é conhecido como conjunto de testes.
    - **Avalie com base em dados representativos:** Certifique-se de que os seus dados de teste representam com precisão os dados do mundo real que o seu modelo irá encontrar.
    - **Considere os objetivos do seu projeto:** As métricas mais importantes para avaliar o seu modelo dependem dos objetivos específicos do projeto. Se evitar falsos

positivos for fundamental, priorize a precisão. Se identificar todas as instâncias de uma classe for crucial, priorize a recuperação.
    - **Avaliação iterativa:** A avaliação é um processo iterativo. Pode ser necessário avaliar o seu modelo várias vezes, ajustar o seu conjunto de dados ou processo de treino, e depois reavaliar para ver se as alterações melhoraram o desempenho.

Ao avaliar cuidadosamente o desempenho do seu modelo usando métricas e boas práticas adequadas, ganha uma compreensão clara dos seus pontos fortes e fracos e toma decisões informadas sobre como o melhorar.

### 3.3.3 Resolução de problemas e aperfeiçoamento do seu modelo

É comum encontrar desafios e áreas a melhorar ao treinar e avaliar o seu projeto de imagem no Teachable Machine. O seu modelo pode não funcionar inicialmente como esperado, ou pode notar fraquezas específicas nas suas previsões. A resolução de problemas e a melhoria iterativa do seu modelo são partes essenciais do processo de aprendizagem automática. Aqui está um guia para o ajudar:

- **Identifique os problemas comuns:**
    - **Baixa precisão:** O modelo faz um grande número de previsões incorretas.
    - **Overfit:** O modelo tem bom desempenho em dados de treino, mas tem um desempenho fraco em dados novos e nunca antes vistos. Isto indica que o modelo aprendeu demasiado bem os dados de treino, incluindo ruído e as suas peculiaridades.

💡 Diagnóstico rápido na sala de aula:

**Porque é que o meu modelo de imagem está a falhar?**

**Ruído de fundo:** Verifica se a IA está a focar-se no sujeito ou no fundo (por exemplo, uma estante desarrumada ou uma janela bem iluminada atrás de ti). Tenta captar dados contra um fundo suave e neutro.

**Overfit do demonstrador:** Se a IA só reconhecer um objeto quando o professor o segura, mas falhar quando um aluno o segura, o modelo aprendeu a sua mão em vez do objeto. Adicione fotografias com mãos e fundos diferentes para corrigir isto.

- **Confusão entre classes:** O modelo tem dificuldade em distinguir entre certas classes, frequentemente classificando mal as imagens de uma classe como pertencentes a outra.
- **Viés:** O modelo tem um desempenho significativamente melhor em alguns grupos ou categorias do que noutros, o que indica um potencial viés nos dados ou modelos.

- **Estratégias para resolução de problemas e melhoria:**
  - **Aumentar a quantidade de dados:** Se o seu modelo tiver baixa precisão, uma solução comum é aumentar a quantidade de dados de treino. Recolha mais imagens para cada classe, garantindo um conjunto de dados equilibrado. Um conjunto de dados maior fornece ao modelo mais informação para aprender, melhorando a sua capacidade de generalizar.
  - **Melhore a qualidade e diversidade dos dados:** Analise dados existentes para identificar imagens de baixa qualidade ou pouco representativas. Substitua imagens desfocadas, distorcidas ou irrelevantes por imagens mais nítidas e focadas. Aumente a diversidade do seu conjunto de dados capturando imagens de diferentes ângulos, em várias condições de iluminação e com diferentes fundos. Aplique técnicas de aumento de dados para aumentar artificialmente a diversidade de dados.
  - **Refinar as suas classes:** Se o seu modelo confundir certas classes, reveja as definições de classes para garantir clareza e distinção. Se necessário, junte classes semelhantes ou crie subclasses mais específicas para reduzir ambiguidades. Certifique-se de que as imagens dentro de cada classe são representativas e não se sobrepõem significativamente com outras classes.
  - **Abordar o overfit:** Quando o seu modelo está a experienciar overfit, considere estas abordagens:
    - Aumento de dados: Como mencionado anteriormente, o aumento de dados ajuda a prevenir o sobreajuste.
    - Simplificar o modelo (se aplicável): Embora o Teachable Machine abstraia grande parte da arquitetura do modelo, em ML mais avançado, simplificar o modelo por vezes ajuda a evitar o sobreajuste.
    - Paragem precoce (se disponível): Alguns sistemas de treino incorporam 'paragem antecipada', onde o treino é interrompido quando o desempenho num conjunto de validação começa a deteriorar-se.
  - **Verifique se há viés:** Analise cuidadosamente o seu conjunto de dados para identificar potenciais fontes de viés. Certifique-se de que os seus dados representam a população para a qual o seu modelo se destina. Se for identificado

algum viés, recolha mais dados para equilibrar o seu conjunto de dados e mitigar o viés. Avalie o desempenho do seu modelo em diferentes grupos e categorias para identificar e corrigir quaisquer disparidades.

- **Treino e avaliação iterativos:** A resolução e melhoria de problemas são processos iterativos. Faça pequenas alterações ao seu conjunto de dados, processo de treino ou definições de classes, depois reforme e reavalie o seu modelo. Acompanhe meticulosamente as alterações feitas e o seu impacto no desempenho. Use métricas de avaliação (precisão, exatidão, recordação, matriz de confusão) para orientar as suas melhorias.
- **Procure ajuda e recursos:** Se estiver a ter dificuldades em melhorar o desempenho do seu modelo, não hesite em procurar ajuda e recursos. Fóruns online, tutoriais e comunidades oferecem informações e orientações valiosas. A documentação e os recursos de suporte da Teachable Machine também fornecem dicas e conselhos úteis para resolução de problemas.

Ao resolver problemas sistematicamente e melhorar iterativamente o seu modelo, supera desafios, melhora o seu desempenho e alcança os resultados desejados nos seus projetos de imagem com a Teachable Machine.

## 3.4 Aplicações na Sala de Aula: IA de Imagem em Ação

### 3.4.1 Atividades de aprendizagem interativas com reconhecimento de imagem

A tecnologia de reconhecimento de imagem, desenvolvida pela Teachable Machine, é uma ferramenta valiosa para criar atividades de aprendizagem envolventes e interativas na sala de aula. Incorporar IA baseada em imagens nas suas aulas proporciona aos alunos experiências práticas, melhora a sua compreensão dos conceitos e promove um ambiente de aprendizagem mais dinâmico. Aqui estão alguns exemplos de atividades de aprendizagem interativas com reconhecimento de imagem:

- **Caças ao tesouro baseadas em imagens:** Crie uma atividade de caça ao tesouro onde os alunos utilizam um modelo da Teachable Machine para identificar objetos ou itens específicos na sala de aula, escola ou ambiente exterior. Os alunos podem usar um tablet ou smartphone equipado com o modelo da Teachable Machine para analisar o ambiente à procura de itens designados. Esta atividade promove competências de observação, incentiva a exploração e torna a aprendizagem mais ativa e agradável. Por exemplo, os alunos mais novos podem procurar diferentes formas, cores ou tipos de folhas, enquanto

os mais velhos podem identificar artefactos históricos, detalhes arquitetónicos ou espécimes científicos.

- **Flashcards interativos:** Desenvolver flashcards interativos que utilizem reconhecimento de imagem é uma forma eficaz de avaliar a compreensão dos conceitos pelos alunos. Em vez de apenas exibir uma palavra ou definição, estes flashcards mostram uma imagem, e os alunos usam depois um modelo de Teachable Machine para a identificar ou classificar. Isto é particularmente útil em disciplinas como ciências, onde os alunos podem identificar animais, plantas ou estruturas anatómicas, ou na aprendizagem de línguas, onde reconhecem objetos e os associam a palavras de vocabulário. A natureza interativa destes flashcards torna a aprendizagem mais envolvente e fornece feedback imediato aos alunos.
- **Narrativa baseada em imagens:** O reconhecimento de imagens pode estimular a criatividade e as atividades de narração de histórias. Os alunos podem usar um modelo de Teachable Machine para identificar objetos ou personagens numa série de imagens e depois usar esses elementos para construir uma história. Esta atividade estimula a imaginação, as competências linguísticas e as capacidades de contar histórias dos alunos. Por exemplo, os alunos podem usar imagens de diferentes animais para criar uma história sobre uma aventura na selva, ou imagens de figuras históricas para escrever um relato ficcionalizado de um evento histórico.
- **Visitas e explorações virtuais:** Crie visitas virtuais ou explorações que aproveitem o reconhecimento de imagens para fornecer aos alunos informações sobre diferentes locais ou objetos. Os alunos podem usar um modelo de Teachable Machine para analisar imagens de marcos, exposições de museus ou ambientes naturais, e aceder a informações, vídeos ou excertos áudio relacionados. Esta atividade oferece experiências de aprendizagem imersivas, permitindo aos alunos explorar locais que de outra forma não visitariam. Por exemplo, os alunos podem fazer uma visita virtual a um local histórico, analisando imagens de edifícios ou artefactos para aprender sobre a sua história, ou explorar um museu virtual, analisando obras de arte para aprender sobre artistas e técnicas.
- **Resolução de problemas baseada em imagem:** Apresente aos alunos problemas ou desafios baseados em imagens que exijam a utilização de um modelo de Teachable Machine para encontrar soluções. Por exemplo, os alunos podem usar um modelo para identificar partes danificadas numa imagem de uma máquina ou classificar diferentes tipos de poluição numa imagem ambiental. Esta atividade desenvolve o pensamento crítico, as competências de resolução de problemas e a capacidade de aplicar conhecimentos a cenários do mundo real.
- **Experiências de aprendizagem personalizadas:** O reconhecimento de imagens pode contribuir para a criação de experiências de aprendizagem personalizadas que se adaptam

às necessidades individuais e aos estilos de aprendizagem dos alunos. Por exemplo, um modelo de Teachable Machine pode acompanhar o progresso dos alunos na identificação de objetos ou conceitos, fornecendo feedback personalizado ou recursos adicionais. Esta abordagem adapta-se a diferentes ritmos de aprendizagem e oferece apoio específico aos alunos.

Estas atividades de aprendizagem interativas demonstram o potencial do reconhecimento de imagens para transformar a experiência em sala de aula, tornando-a mais envolvente, interativa e eficaz.

### 3.4.2 Integração da IA de imagem em Disciplinas Específicas

As capacidades de reconhecimento de imagens da Teachable Machine integram-se perfeitamente numa vasta gama de aulas específicas de cada disciplina, enriquecendo o currículo e proporcionando aos alunos experiências de aprendizagem únicas. Ao adaptar os designs de IA de imagem a disciplinas específicas, os educadores aumentam o envolvimento dos alunos, promovem uma compreensão mais profunda e promovem a aprendizagem interdisciplinar. Aqui estão alguns exemplos de como integrar IA de imagens em diferentes disciplinas do ensino básico:

- **Ciências da Vida e Físicas:**
  - **Biologia:** Podem ser criados projetos que classifiquem diferentes tipos de plantas (por exemplo, folhas, flores), animais (por exemplo, fauna local, animais de estimação), fungos ou até microrganismos a partir de imagens ampliadas. Os alunos podem recolher imagens de espécimes no terreno ou utilizar imagens existentes em manuais escolares ou recursos online. O reconhecimento de imagens ajuda a identificar diferentes fases do ciclo de vida, analisar estruturas celulares (se forem usadas ampliações apropriadas) ou classificar organismos com base nas suas características.
  - **Ciências da Terra:** Podem ser desenvolvidos projetos que classifiquem diferentes tipos de rochas, minerais, nuvens ou padrões meteorológicos. Os alunos podem recolher imagens de amostras geológicas ou fenómenos meteorológicos, usando reconhecimento de imagens para as identificar e categorizar. A IA de imagens também pode analisar imagens de satélite, identificar formas de relevo ou acompanhar alterações ambientais.
  - **Astronomia:** Criar projetos que classifiquem vários objetos celestes, como estrelas, planetas, galáxias ou nebulosas. Os alunos utilizam imagens de telescópios ou sondas espaciais para identificar e classificar estes objetos. O reconhecimento de

imagens ajuda a analisar imagens astronómicas, identificar constelações ou rastrear o movimento dos corpos celestes.

- **Língua e Comunicação:**
  - **Desenvolvimento do vocabulário visual:** Podem ser desenvolvidos projetos que ligam imagens a palavras de vocabulário numa língua-alvo. Os alunos usam imagens para aprender novas palavras, melhorar o vocabulário ou praticar competências linguísticas. O reconhecimento de imagens facilita a criação de flashcards interativos, dicionários ilustrados ou jogos de aprendizagem de línguas.
  - **Reconhecimento de Personagens e Cenários:** Crie projetos que reconheçam e identifiquem personagens, objetos ou cenários da literatura ou das histórias. Os alunos utilizam imagens de ilustrações de livros ou desenhos criados por eles próprios para aprender sobre características, papéis ou relações na narrativa. A Image AI pode gerar perfis interativos de personagens ou resumos de histórias.
- **História e Ciências Sociais:**
  - **Análise de artefactos:** Podem ser desenvolvidos projetos que identifiquem e classifiquem artefactos históricos, como ferramentas, armas, cerâmica ou vestuário. Os alunos utilizam imagens de artefactos de museus ou sítios arqueológicos para aprender sobre diferentes culturas e períodos históricos. O reconhecimento de imagens permite-lhes analisar o estilo, os materiais ou a função dos artefactos.
  - **Figuras históricas e marcos históricos: Crie** projetos que reconheçam e identifiquem figuras históricas a partir de retratos ou fotografias, ou que classifiquem marcos históricos (edifícios, monumentos, sítios arqueológicos). Os alunos utilizam estas imagens para aprender sobre significado histórico, características arquitetónicas ou contexto cultural.
- **Artes visuais e design:**
  - **Classificação de estilos artísticos:** Podem ser criados projetos que classifiquem diferentes estilos artísticos, como pintura, escultura ou arquitetura. Os alunos utilizam imagens de obras de arte para aprender sobre as características, técnicas ou contexto histórico de diferentes estilos. O reconhecimento de imagens permite-lhes analisar a composição, paleta de cores ou tema.
  - **Reconhecimento do artista:** Desenvolver projetos que reconheçam e identifiquem diferentes artistas a partir das suas obras. Os alunos utilizam imagens das obras para aprender sobre a vida dos artistas, influências ou desenvolvimento artístico. A Image AI pode gerar questionários interativos sobre arte ou biografias de artistas.

Estes exemplos ilustram a versatilidade da IA de imagem na educação, demonstrando a sua adaptabilidade para melhorar a aprendizagem em múltiplas disciplinas. Integrar projetos de

imagens da Teachable Machine em aulas específicas permite aos educadores criar experiências de aprendizagem envolventes, interativas e eficazes para os seus alunos.

**Tabela resumida: Visão geral dos projetos interdisciplinares de imagem:**

| Disciplina | Ideia de Projeto de Sala de Aula | Objetivo de Aprendizagem |
|---|---|---|
| Ciências da Vida e Ciências Físicas | Classifica folhas de plantas, tipos de nuvens, rochas, microrganismos ou corpos celestes. | Identificar características das espécies, analisar amostras geológicas e estudar padrões meteorológicos ou espaços. |
| Língua e Comunicação | Associe imagens a palavras na língua-alvo ou reconheça personagens e cenários de histórias. | Reforçar a aquisição de vocabulário através de feedback visual da IA. |
| História e Ciências Sociais | Identificar artefactos de museu, figuras históricas a partir de retratos ou arquitetura emblemática. | Explore culturas antigas, analise a importância histórica e estude estilos arquitetónicos. |
| Artes visuais e design | Classifique estilos artísticos (pintura, escultura) ou reconheça artistas específicos pelas suas obras. | Analise composições visuais, paletas de cores, técnicas de pinceladas e história da arte. |

### 3.4.3 Estratégias de avaliação utilizando projetos de IA baseados em imagem

Projetos de IA baseados em imagens, criados com a Teachable Machine, servem como ferramentas valiosas para várias estratégias de avaliação destinadas a avaliar a aprendizagem dos alunos, fornecer feedback e acompanhar o progresso. Estes projetos oferecem oportunidades únicas para avaliações autênticas, permitindo aos alunos demonstrar compreensão e competências de forma prática e envolvente. Aqui estão alguns exemplos de estratégias de avaliação que utilizam projetos de IA baseados em imagens:

- **Avaliação baseada em projetos:** Atribuir projetos de IA baseados em imagens como principal tarefa de avaliação exige que os alunos desenhem, desenvolvam e avaliem os seus próprios modelos de reconhecimento de imagem. Avalie a compreensão dos alunos

sobre os conceitos e competências envolvidos, como recolha de dados, treino de modelos, avaliação e aplicação. Avalie a qualidade dos seus projetos, incluindo a precisão do modelo, funcionalidade e criatividade. Proporcione oportunidades para os alunos apresentarem os seus projetos, explicando as suas escolhas de design e as conclusões a que chegaram. A avaliação baseada em projetos permite uma avaliação holística da aprendizagem dos alunos e proporciona-lhes um sentido de propriedade do seu trabalho.

- **Avaliação baseada no desempenho:** O uso de projetos de IA baseados em imagens avalia a capacidade dos alunos para aplicar conhecimentos e competências em situações práticas. Apresentar aos alunos cenários ou desafios do mundo real que os exijam a usar os seus modelos para resolução de problemas ou tomada de decisões. Avaliar o seu desempenho com base na precisão e eficácia das previsões do modelo, bem como na sua capacidade de interpretar e utilizar os resultados. Por exemplo, os alunos podem usar um modelo para identificar doenças das plantas e recomendar tratamentos, ou classificar diferentes tipos de poluição e propor soluções de remediação ambiental.
- **Avaliação formativa:** Projetos de IA baseados em imagens podem ser integrados em atividades de avaliação formativa para acompanhar a aprendizagem dos alunos e fornecer feedback contínuo. Use modelos do Teachable Machine para criar questionários interativos, jogos ou atividades que permitam aos alunos verificar a sua compreensão dos conceitos. Forneça aos alunos feedback imediato sobre as respostas e identifique áreas que necessitam de apoio adicional. A avaliação formativa com IA de imagens ajuda os alunos a acompanhar o progresso e a identificar áreas a melhorar.
- **Autoavaliação e avaliação entre pares:** Incentive os alunos a utilizarem projetos de IA baseados em imagens para autoavaliação e avaliação entre pares. Isto promove metacognição, pensamento crítico e competências de colaboração. Os alunos utilizam os seus modelos para avaliar a sua própria compreensão ou para dar feedback aos colegas nos projetos. Fornecer aos alunos critérios e diretrizes claros para autoavaliação e avaliação entre pares.
- **Avaliação do portefólio:** Inclua projetos de IA baseados em imagens nos portefólios dos alunos para mostrar a sua aprendizagem e competências desenvolvidas ao longo do tempo. Os portefólios oferecem uma visão abrangente do crescimento e desenvolvimento dos alunos, destacando pontos fortes, competências e progresso. Os alunos escolhem os seus melhores projetos para inclusão e refletem sobre as suas experiências de aprendizagem.

Exemplos de tarefas de avaliação:

- "Desenhar um modelo de reconhecimento de imagem que classifique diferentes tipos de nuvens e o utilize para prever padrões meteorológicos."

- "Desenvolver um questionário baseado em imagens que teste o conhecimento dos alunos sobre figuras históricas e as suas contribuições."
- "Criar uma avaliação baseada no desempenho, onde os alunos utilizam um modelo de reconhecimento de imagem para identificar doenças das plantas e recomendar tratamentos adequados."
- "Use um modelo de Teachable Machine para criar uma atividade interativa que ajude os alunos a aprender novas palavras de vocabulário numa língua estrangeira."

Ao incorporar projetos de IA baseados em imagens numa variedade de estratégias de avaliação, os educadores criam formas autênticas, envolventes e eficazes de avaliar a aprendizagem dos alunos e promover uma compreensão mais profunda.

📝Nota:

Depois de treinar um modelo de imagem, os alunos podem clicar em "Exportar Modelo" e escolher a opção "Link Partilhável". Isto gera uma URL pública que permite aos alunos enviar o seu modelo de IA funcional ao professor ou colegas. Qualquer pessoa com o link pode testar o modelo na webcam do seu próprio dispositivo, sem precisar de o reeducar do zero!

# Módulo 4: Criação de Projetos de Áudio

Para além do reconhecimento de imagem, o Teachable Machine estende as suas capacidades ao áudio. Este módulo orienta-o no processo de desenvolvimento de modelos de aprendizagem automática capazes de reconhecer e classificar diferentes sons, vozes ou padrões musicais. Compreender como criar projetos áudio abre novas vias para aprendizagem interativa na sua sala de aula.

## 4.1 Planeamento de projetos: Defina a sua IA baseada em áudio

Um planeamento e preparação cuidadosos são passos cruciais antes de iniciar o seu primeiro projeto áudio no Teachable Machine. Estas fases iniciais envolvem definir o âmbito do projeto, identificar aplicações adequadas e estabelecer critérios claros de sucesso.

### 4.1.1 Identificar aplicações em sala de aula para reconhecimento áudio

O reconhecimento de áudio, impulsionado por Aprendizagem Automática, apresenta inúmeras oportunidades para enriquecer o ensino e a aprendizagem na sala de aula. Esta tecnologia cria experiências interativas baseadas no som, automatiza tarefas que envolvem entrada de áudio e ajuda os alunos a explorar o mundo através do som de novas formas. Aqui estão alguns exemplos de aplicações em sala de aula para reconhecimento áudio:

- **Identificação e classificação sonora:** O reconhecimento sonoro é útil para criar "Fezes" que ajudam os alunos a identificar e classificar sons. Esta aplicação é particularmente valiosa em áreas como ciências (por exemplo, identificação de sons de animais, diferentes sons meteorológicos como trovões ou chuva, ou sons de vários materiais) ou música (reconhecimento de sons de instrumentos). Por exemplo, os alunos podem desenvolver um projeto para identificar diferentes cantos de aves ou classificar sons associados a ambientes específicos (por exemplo, floresta, cidade). Esta atividade melhora as capacidades de compreensão auditiva dos alunos, o pensamento crítico sobre as propriedades do som e a compreensão dos ambientes acústicos.
- **Comandos de voz e interação:** A integração do reconhecimento de áudio permite atividades interativas onde os alunos usam a voz para dar ordens a um sistema ou interagir com conteúdos digitais. Os professores, por exemplo, podem criar um sistema onde os alunos dizem uma palavra e o sistema responde com uma definição, ou um jogo onde comandos de voz controlam personagens no ecrã. Isto torna a aprendizagem altamente interativa e pode apoiar alunos com diferentes estilos de aprendizagem.
- **Aprendizagem de línguas e prática de pronúncia:** O reconhecimento áudio oferece benefícios significativos para a aquisição da língua. Os alunos podem criar projetos que identificam e fornecem feedback sobre a pronúncia de palavras ou frases numa nova língua. Isto fornece feedback imediato e personalizado, ajudando os alunos a aprimorar as

suas competências de fala. Por exemplo, um modelo pode ser treinado para distinguir entre pronúncias corretas e incorretas do vocabulário alvo.

- **Educação musical:** Explore aplicações na educação musical usando reconhecimento áudio. Os alunos podem criar projetos que reconhecem diferentes notas musicais, acordes ou instrumentos. Isto promove a compreensão dos elementos musicais e pode apoiar atividades interativas de composição ou apreciação musical.
- **Tecnologias assistivas:** O reconhecimento de áudio pode ser usado para desenvolver tecnologias assistivas para alunos com deficiência auditiva ou outras necessidades especiais. Um projeto, por exemplo, pode ajudar a identificar sons ambientais comuns (como a campainha ou o toque do telefone) e fornecer alertas visuais, ou ajudar alunos com dificuldades de fala ao reconhecer padrões vocais. Esta aplicação promove a inclusão e oferece apoio personalizado aos alunos.
- **Melhorar a narrativa e as artes criativas:** Integre o reconhecimento de áudio nas atividades de artes criativas e narrativa. Os alunos podem usar um modelo de Teachable Machine para ativar diferentes sons ou músicas com base nas suas vocalizações ou ruídos ambientes, criando paisagens sonoras interativas ou enriquecendo experiências narrativas. Isto estimula a criatividade e explora a expressão multimodal.

Estes exemplos representam apenas algumas das muitas aplicações do reconhecimento de áudio na sala de aula. As possibilidades são vastas, limitadas apenas pela criatividade e engenho dos educadores e alunos.

### 4.1.2 Escolha de sons ou padrões de voz adequados para classificação

Selecionar os sons ou padrões de voz certos para o seu projeto áudio é crucial para garantir o seu sucesso e valor educativo. As suas escolhas influenciam diretamente a complexidade do projeto, a viabilidade da recolha de dados e a sua relevância para os seus objetivos de aprendizagem. Aqui estão algumas considerações chave para escolher sons ou padrões de voz adequados para classificação no Teachable Machine:

- **Simplicidade e distintividade:** Comece com sons ou padrões de voz que sejam acusticamente distintos e fáceis de diferenciar. Evite categorias que soem demasiado semelhantes ou que tenham diferenças subtis, pois estas podem ser difíceis de aprender para o modelo. Por exemplo, em vez de tentar distinguir entre diferentes tipos de latidos de cães (o que pode ser desafiante devido às variações), comece por algo mais simples, como classificar sons de animais de diferentes espécies (por exemplo, o latido de um cão, o miado de um gato, o chilrear de um pássaro). À medida que os aprendizes ganham experiência, podem gradualmente avançar para tarefas de classificação mais complexas.

- **Relevância para os objetivos de aprendizagem:** Escolha sons ou padrões vocais que estejam diretamente alinhados com os seus objetivos específicos de aprendizagem e objetivos curriculares. Selecione categorias que ajudem os alunos a adquirir novas informações, desenvolver competências específicas ou explorar tópicos relevantes. Por exemplo, numa aula de ciências dos ecossistemas, os alunos podem criar um projeto para classificar os sons de diferentes animais encontrados num habitat específico. Se estiver a ensinar uma aula de línguas, os alunos podem criar um projeto para identificar diferentes sons vocálicos ou frases comuns. Certifique-se de que o projeto apoia e melhora a experiência geral de aprendizagem.
- **Viabilidade da recolha de dados:** Considere a facilidade e praticidade de recolher dados suficientes para os sons ou padrões de voz escolhidos. Selecione categorias para as quais possa obter facilmente um conjunto de dados diversificado e representativo. Se quiser gravar áudio usando um microfone, escolha sons que sejam facilmente reproduzidos ou graváveis na sua sala de aula ou ambiente de aprendizagem. Se utilizar áudio existente, certifique-se de que tem acesso a uma coleção adequada online ou de outros recursos. Evite categorias que sejam difíceis de capturar, que exijam equipamento de gravação especializado ou que sejam eticamente sensíveis (por exemplo, conversas privadas).
- **Clareza sobre categorias:** Defina categorias claras e inequívocas para o seu projeto. Certifique-se de que há sobreposição ou ambiguidade mínima entre estas categorias. Cada categoria deve representar um padrão sonoro ou de voz distinto e bem definido. Evite categorias demasiado amplas ou facilmente confundíveis entre si. Por exemplo, em vez de categorias amplas como 'música' e 'fala', opte por categorias separadas como 'música clássica', 'música pop' e 'fala infantil'.
- **Envolvimento e interesse dos alunos:** Escolha sons ou padrões de voz que possam despertar e despertar o interesse dos seus alunos. Selecione categorias que sejam relevantes para as suas vidas, hobbies ou interesses. O interesse dos alunos num projeto traduz-se frequentemente em maior motivação para participação e aprendizagem. Considere envolver os alunos no processo de seleção, fazer brainstorming (chuva) de ideias e permitir que escolham categorias apelativas.
- **Considerações éticas:** Considere sempre quaisquer considerações éticas relacionadas com os sons ou padrões de voz que escolher. Evite categorias que possam ser ofensivas, discriminatórias ou prejudiciais. Se estiver a trabalhar com dados de voz, certifique-se de que o consentimento adequado é obtido e que a privacidade é protegida. Escolha categorias que promovam valores positivos e o uso responsável da tecnologia.

Ao considerar cuidadosamente estes fatores, selecione sons ou padrões de voz adequados para os seus projetos de áudio na Teachable Machine, garantindo que são educativos valiosos, envolventes e eticamente corretos.

### 4.1.3 Definição dos critérios de sucesso do projeto

Estabelecer critérios claros de sucesso antes de iniciar o seu projeto áudio na Teachable Machine é crucial para avaliar a sua eficácia e determinar se atingiu o objetivo pretendido. Os critérios de sucesso fornecem um parâmetro contra o qual pode medir o desempenho do seu projeto e identificar áreas a melhorar. Também o ajudam a manter o foco durante o processo de desenvolvimento e a garantir que se mantém no caminho certo para alcançar os seus objetivos. Aqui está um guia para definir critérios eficazes de sucesso para projetos áudio:

- **Precisão e métricas de desempenho:** Definir objetivos para a precisão e desempenho do seu modelo de reconhecimento áudio é uma forma comum de definir sucesso.
    - **Precisão geral:** Determinar a percentagem mínima aceitável de avaliações corretas. Por exemplo, um objetivo pode ser alcançar 90% de precisão global, o que significa que o modelo classifica corretamente 90% das amostras de áudio que lhe são apresentadas.
    - **Precisão específica da classe:** Para classes mais importantes ou desafiantes (por exemplo, distinguir palavras específicas num ambiente ruidoso), podem ser definidas metas de precisão específicas para cada uma. Pode ser necessária maior precisão para identificar sons críticos num projeto de alerta de segurança.
    - **Precisão e recordação (simplificado):** Estas métricas dão-lhe uma compreensão mais detalhada de como o seu modelo está a funcionar. A precisão indica com que frequência o modelo estava correto quando dizia que algo pertencia a uma determinada classe. Recorde-se mede com que frequência o modelo identificou corretamente algo que *realmente* pertencia a uma determinada classe. Um modelo equilibrado geralmente tem um bom desempenho em ambos os aspetos.
    - **Tempo de resposta:** Se for necessário reconhecimento de áudio em tempo real (por exemplo, para comandos de voz), defina um objetivo para o tempo máximo aceitável de resposta. Isto mede o tempo que o modelo demora a processar uma entrada de áudio e a fornecer uma classificação.
- **Funcionalidade e usabilidade:** Defina critérios relacionados com a funcionalidade e usabilidade do seu projeto, especialmente se este tiver como alvo uma aplicação ou grupo de utilizadores específico.
    - **Facilidade de utilização:** Se o seu projeto inclui uma interface de utilizador, devem ser definidos critérios quanto à sua facilidade de utilização e intuitividade. Considere

se os utilizadores conseguem interagir facilmente com o modelo e compreender os seus resultados.
    - **Integração:** Para projetos destinados à integração com outro sistema ou aplicação, defina critérios para uma integração bem-sucedida. Verifique se a ligação é feita de forma fluida e que existe troca de dados com o outro sistema.
    - **Acessibilidade:** Se o seu projeto for direcionado a um grupo diversificado de utilizadores, estabeleça critérios relativos à sua acessibilidade. É utilizável por pessoas com deficiência auditiva ou outras necessidades especiais (por exemplo, através de feedback visual)?
- **Impacto educativo (se aplicável):** Para projetos concebidos com fins educativos, defina critérios relacionados com o seu impacto na aprendizagem dos alunos.
    - **Resultados de aprendizagem:** O projeto ajuda os aprendentes a alcançar os resultados de aprendizagem desejados? Os alunos conseguem demonstrar um aumento de conhecimentos ou competências após a utilização do projeto, como melhor escuta ou pronúncia?
    - **Envolvimento:** O projeto envolve os alunos e motiva-os a aprender? Os alunos acham o projeto interessante e agradável?
    - **Feedback dos alunos:** Recolha feedback dos alunos sobre a sua experiência com o projeto. Acham útil, informativo ou agradável?
- **Requisitos técnicos:** Defina critérios relacionados com quaisquer requisitos técnicos específicos do seu projeto.
    - **Compatibilidade de plataformas:** O projeto funciona corretamente nas plataformas ou dispositivos pretendidos?
    - **Utilização de recursos:** O projeto utiliza os recursos de forma eficiente? Corre de forma fluida sem consumir excesso de poder de processamento ou memória?
- **Considerações éticas:** Incorpore considerações éticas nos seus critérios de sucesso.
    - **Mitigação de preconceito:** O projeto demonstra justiça e minimiza o viés nas suas previsões (por exemplo, relativamente a diferentes sotaques ou tons de voz)?
    - **Proteção de privacidade:** O projeto protege a privacidade dos utilizadores e trata os dados de áudio de forma responsável?

Exemplos de critérios de sucesso para projetos áudio:

- "O modelo de reconhecimento áudio atinge uma precisão global de 88% na classificação de diferentes sons de animais."
- "Os alunos que utilizam o projeto de feedback de pronúncia demonstram uma melhoria de 15% na correta pronúncia das palavras do vocabulário alvo."

- "A ferramenta de reconhecimento sonoro ambiental identifica corretamente 90% dos ruídos domésticos comuns e fornece alertas visuais apropriados."

Ao definir critérios de sucesso claros, mensuráveis e relevantes, orienta eficazmente o desenvolvimento do seu projeto áudio Teachable Machine e assegura que cumpre os seus objetivos pretendidos.

## 4.2 Recolha e preparação de dados: Construir o seu conjunto de dados para áudio

Os dados são o motor de qualquer modelo de Aprendizagem Automática. A qualidade, quantidade e diversidade dos seus dados áudio têm um impacto direto no desempenho e na precisão do seu projeto Teachable Machine. Por isso, planear uma estratégia robusta de recolha de dados é essencial para construir um modelo bem-sucedido.

### 4.2.1 Recolha de dados áudio: fontes e métodos

A qualidade e diversidade do seu conjunto de dados áudio são críticas para o sucesso do seu projeto áudio na Teachable Machine. Um conjunto de dados bem construído permite que o seu modelo aprenda eficazmente e faça previsões precisas. Esta secção descreve várias fontes e métodos para recolher dados áudio:

- **Gravação por microfone:** A Teachable Machine oferece uma funcionalidade útil que permite capturar áudio diretamente usando o microfone do seu computador. Este método é particularmente útil para recolher sons ou amostras de voz facilmente reproduzíveis específicas para o seu projeto.
    - **Vantagens:**
        - A recolha de dados é fácil e rápida para entradas em tempo real.
        - É possível controlar diretamente as características do som (por exemplo, volume, clareza).
        - É suportada a captura em tempo real de sons ou padrões de voz específicos.
    - **Considerações:**
        - O ruído ambiental pode interferir com as gravações; garantir um ambiente de gravação silencioso.
        - A qualidade do microfone pode afetar a clareza dos dados de áudio.
        - Sons ou vozes devem ser reproduzíveis para uma recolha consistente de dados.

💡 Dica do professor:

**A "Regra de Ouro" para o ruído de fundo áudio:** Não grave a sua aula de "Ruído de Fundo" em total silêncio! Em vez disso, grave 20 a 30 segundos do ruído ambiente real da sua sala de aula (como sussurros distantes, o arrastar das cadeiras, cliques do teclado ou o zumbido do ar condicionado). Isto ensina à IA quais os sons ambientais específicos que deve ignorar ao ouvir comandos de voz ou disparadores acústicos.

- **Bibliotecas e bases de dados de áudio existentes:** Numerosas bibliotecas de áudio e bases de dados online oferecem vastas coleções de sons e gravações de voz adequadas para os seus projetos na Teachable Machine. Estes recursos são particularmente úteis para aceder a sons que não são facilmente graváveis no seu ambiente.
  - **Exemplos de funcionalidades:**
    - Freesound: Oferece uma base de dados colaborativa de excertos áudio, efeitos e gravações.
    - Soundbible: Fornece excertos sonoros gratuitos para vários usos.
    - Bases de dados especializadas: Dependendo do seu projeto, podem estar disponíveis bases de dados especializadas (por exemplo, bases de dados de sons ambientais, corpora de fala).
  - **Vantagens:**
    - O acesso a uma grande variedade de sons e padrões de voz é garantido.
    - Poupa tempo e esforço em comparação com gravar todo o áudio sozinho.
    - É possível aceder a sons ou vozes que, de outra forma, seriam difíceis de obter.
  - **Considerações:**
    - Por favor, note as restrições de direitos de autor e os direitos de utilização para fins comerciais ou públicos.
    - A qualidade e consistência do áudio podem variar consoante a fonte.
    - Uma filtragem cuidadosa ou seleção de áudio garante a relevância para o seu projeto e o tratamento ético dos dados de voz.
- **Coleções pessoais de áudio:** Se tiver uma coleção pessoal de gravações áudio (por exemplo, notas de voz, efeitos sonoros), algumas podem ser utilizáveis no seu projeto Teachable Machine. Esta pode ser uma boa opção para recolher sons únicos ou familiares.
  - **Vantagens:**
    - Acesso fácil a uma coleção de áudio existente.
    - As gravações provavelmente serão relevantes para o seu contexto.

        - Um toque pessoal é acrescentado ao seu projeto.
    - **Considerações:**
        - Certifica-te de que tens o direito de usar o áudio.
        - A qualidade e consistência do áudio podem variar.
        - Uma seleção cuidadosa garante a adequação para o seu projeto e protege a privacidade.
- **Upscale de áudio:** Esta técnica envolve aumentar artificialmente o tamanho e a diversidade do seu conjunto de dados aplicando várias transformações a amostras de áudio existentes. Este pode ser um método valioso para melhorar o desempenho do seu modelo.
    - **Exemplos de técnicas de aumento:**
        - **Adicionar ruído:** Introduzir ruído de fundo (por exemplo, ruído branco, sons ambientais comuns) ajuda o modelo a tornar-se mais robusto perante condições reais e ruidosas.
        - **Alteração de Afinação:** Ajustar a afinação das amostras de áudio ajuda o modelo a reconhecer sons em diferentes frequências.
        - **Alterar a duração:** Alterar a velocidade das amostras de áudio sem alterar a afinação ajuda o modelo a reconhecer sons em tempos variados.
        - **Ajustes de volume:** Variar o volume das amostras de áudio torna o modelo mais resistente a diferentes níveis de intensidade sonora.
    - **Vantagens:**
        - Isto aumenta o tamanho e a diversidade do seu conjunto de dados sem necessidade de recolher novos ficheiros de áudio.
        - Pode melhorar a capacidade do seu modelo de generalizar e lidar com variações de áudio.
        - Ajuda a evitar o sobreajuste (quando o modelo aprende demasiado bem os dados de treino e tem um desempenho fraco com dados novos).
    - **Considerações:**
        - Use técnicas de aumento com discernimento; evite transformar o áudio ao ponto de deixar de soar realista.
        - Tenha em conta os requisitos específicos do seu projeto e escolha técnicas de aumento relevantes para as variações que o seu modelo provavelmente irá encontrar.
        - Acompanhe o desempenho do seu modelo num conjunto de validação (dados não usados para treino) para garantir que o aumento melhora a generalização e não prejudica o desempenho.

Ao recolher dados de áudio, é crucial dar prioridade à qualidade, diversidade e relevância. Certifique-se de que as suas amostras áudio são claras, sem ruído de fundo excessivo e representativas dos sons ou padrões de voz que o seu modelo deve reconhecer.

### 4.2.2 Criação de Classes de Áudio: Definição de Categorias para o Seu Modelo

No Teachable Machine, as "classes" representam as categorias ou rótulos distintos que o seu modelo de reconhecimento de áudio aprende a identificar. Definir estas classes de forma clara e precisa é um passo crucial na preparação do seu conjunto de dados e na garantia de que o seu modelo distingue eficazmente entre diferentes sons ou padrões de voz. Aqui está um guia para criar classes de áudio:

- **Defina claramente as suas categorias:** Antes de adicionar amostras de áudio, dedique algum tempo a definir cuidadosamente as categorias que o seu modelo irá reconhecer. Cada classe deve representar um som, padrão de voz ou classificação específico que seja relevante para os objetivos do seu projeto. Certifique-se de que as categorias são bem definidas, inequívocas e mutuamente exclusivas (tanto quanto possível). Isto significa que deve haver sobreposição ou confusão mínima entre as categorias. Por exemplo, ao classificar sons de animais, as classes podem ser "latido de cão", "miado de gato", "canto de pássaro" e "mugido de vaca".
- **Determine o número de aulas:** O número de aulas de que precisa depende da complexidade do seu projeto e do número de sons ou padrões de voz distintos a reconhecer. Comece com um número razoável, especialmente se for principiante. Pode sempre adicionar aulas adicionais mais tarde, se necessário. Considere o compromisso entre o número de aulas e os dados de que precisa; mais aulas geralmente exigem mais dados para um treino eficaz de modelos.
- **Dê** nomes apropriados **às suas turmas:** Dê às suas turmas nomes claros e descritivos que reflitam com precisão os sons ou padrões vocais que representam. Isto ajuda na organização e garante uma compreensão fácil do propósito de cada turma. Use convenções de nomenclatura consistentes, por exemplo, descrições específicas de sons (por exemplo, "tocar o sino" em vez de apenas "tocar") ou rótulos vocais claros.
- **Criar classes na Teachable Machine:** A Teachable Machine oferece uma interface intuitiva para criar e gerir classes. Existe uma área disponível para adicionar novas classes, renomear as existentes ou eliminar classes. Siga as instruções no ecrã para criar as suas turmas e atribuir nomes apropriados.
- **Considere as implicações éticas dos dados de voz:** Ao trabalhar com dados de voz ou de fala, esteja sempre particularmente atento às considerações éticas. Certifique-se de que tem o consentimento adequado para gravar vozes, especialmente as dos alunos.

Priorize a privacidade e evite recolher qualquer informação pessoal sensível através de áudio.

- **Revise e aperfeiçoe as suas aulas:** Depois de criar o seu conjunto inicial de aulas, reveja-as cuidadosamente para garantir que são adequadas aos objetivos do seu projeto. Considere se precisa de adicionar, remover ou renomear classes. Muitas vezes, refinar classes torna-se útil depois de começar a recolha de dados, à medida que adquire uma melhor compreensão das variações dos dados.

Ao definir e criar cuidadosamente as suas aulas de áudio, estabelece uma base sólida para o seu projeto de áudio no Teachable Machine, garantindo que o seu modelo aprende eficazmente a distinguir entre as categorias especificadas.

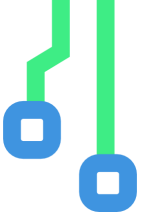
### 4.2.3 Aumento de dados de de Áudio: Melhorar o Seu Conjunto de Dados

O upscaling de áudio é uma técnica poderosa para aumentar artificialmente o tamanho e a diversidade do seu conjunto de dados de áudio. Isto envolve aplicar várias transformações a amostras de áudio existentes para criar novas versões, ligeiramente modificadas. Este método pode melhorar significativamente a robustez e a generalização do seu projeto de áudio Teachable Machine, ajudando-o a ter um bom desempenho em dados nunca antes vistos, especialmente em ambientes reais com condições de áudio variadas. Aqui está um guia sobre upscale de áudio:

- **Por que usar o Áudio Boost?**
  - **Aumento do tamanho do conjunto de dados:** Aumentar permite gerar mais dados de treino a partir de áudio existente, expandindo efetivamente o seu conjunto de dados sem necessidade de recolher novas amostras. Isto é particularmente útil quando as gravações áudio originais são limitadas.
  - **Melhor generalização:** Ao introduzir variações nos seus dados de treino, a ampliação ajuda o modelo a aprender características mais robustas e a tornar-se menos sensível a características específicas do áudio de treino. Isto melhora a capacidade do modelo de generalizar para áudio novo, nunca antes visto, que pode diferir ligeiramente dos dados de treino.
  - **Redução do sobreajuste:** O sobreajuste ocorre quando um modelo aprende demasiado bem os dados de treino, incluindo ruído e as suas peculiaridades, o que leva a um desempenho fraco em novos dados. O aumento ajuda a prevenir o sobreajuste ao tornar o modelo menos dependente de exemplos específicos de treino e ao incentivá-lo a aprender características mais generalizáveis para várias entradas de áudio.
- **Técnicas comuns de aumento:**

- **Adicionar ruído:** Introduzir ruído de fundo (por exemplo, ruído branco, sons comuns de sala de aula, ruído de rua) ajuda o modelo a tornar-se mais robusto perante condições ruidosas do mundo real. Isto simula ambientes mais realistas.
- **Alteração** do tom **do som:** Ajustar o tom sonoro das amostras de áudio ajuda o modelo a reconhecer sons ou vozes em diferentes frequências, o que pode ocorrer naturalmente (por exemplo, diferentes colunas, variações do instrumento).
- **Alterar a duração:** Alterar a velocidade das amostras de áudio sem alterar a altura ajuda o modelo a reconhecer sons em tempos variados. Isto é útil para reconhecimento de fala ou variações no ritmo musical.
- **Ajustes de volume:** Variar o volume das amostras de áudio torna o modelo mais resistente a diferentes níveis de intensidade sonora. Isto prepara o modelo para gravações com volumes de gravação variados ou distâncias variadas da fonte sonora.
- **Inserir mute:** Adicionar curtos períodos de silêncio no início ou no fim dos clips de áudio pode tornar o modelo mais robusto perante durações e pausas de áudio variadas.

- **Aplicação de Amplificação de Áudio:**
  - **Funcionalidades integradas da Teachable Machine:** Embora a Teachable Machine trate internamente de alguns aspetos do processamento de som, as suas funcionalidades de aumento direto são mais limitadas em comparação com ferramentas externas. Foque-se em fornecer amostras originais diversificadas.
  - **Ferramentas e bibliotecas externas (para exploração avançada):** Para aplicar técnicas específicas de aumentação, como adicionar ruído ou alterar o tom, normalmente utilizam-se softwares externos de edição de áudio (por exemplo, Audacity) ou bibliotecas de programação (como Librosa ou Python's Audiomentations). Para professores do ensino básico, focar-se em fornecer amostras originais variadas e de boa qualidade é frequentemente a abordagem mais eficaz para projetos mais simples; estas ferramentas externas destinam-se a uma exploração mais aprofundada e desafios mais complexos.
- **Melhores Práticas de Aumento:**
  - Aplica as técnicas de aumento com sabedoria. Evita aumentar demasiado os dados ao ponto de o áudio transformado deixar de soar realista ou representativo dos originais.
  - Tenha em conta os requisitos específicos do seu projeto e escolha técnicas de aumento relevantes para as variações que o seu modelo provavelmente encontrará no áudio do mundo real.



- Monitorize o desempenho do seu modelo num conjunto de validação (dados não usados para treino) para garantir que o aumento melhora a generalização e não prejudica o desempenho.

Ao utilizar eficazmente o audio boost, melhora a robustez, precisão e generalização dos seus projetos de áudio Teachable Machine, levando a modelos de reconhecimento sonoro mais fiáveis e eficazes, especialmente em ambientes acústicos variados.

### 4.2.4 Prepare os seus dados para o Teachable Machine

Depois de recolher os seus dados de áudio e aplicar as técnicas de aumento desejadas, o passo seguinte é prepará-los para uso no Teachable Machine. A preparação adequada dos dados garante que os seus samples de áudio estão no formato correto, organizados de forma eficaz e prontos para treinar o seu modelo de ML. Aqui está um guia para preparar os seus dados:

- **Formatos de ficheiro de áudio:** A Teachable Machine normalmente suporta os formatos de ficheiro de áudio mais comuns. O WAV (.wav) é frequentemente preferido pela sua qualidade não comprimida, mas MP3 (.mp3) ou outros formatos comuns também podem ser suportados. Certifique-se de que as suas amostras de áudio são guardadas num formato compatível. Se forem usados outros formatos, pode ser necessária conversão através de software de edição de áudio ou ferramentas online.
- **Duração do áudio e segmentação:** Considere o comprimento dos seus samples de áudio. Para deteção de eventos (por exemplo, palmas, buzzer), clips curtos e distintos são ideais. Para fala, são necessários clipes mais longos que contenham a frase. Se estiver a trabalhar com áudio contínuo, é necessária a segmentação em clipes menores e mais fáceis de gerir correspondentes a cada classe. Manter a consistência na duração dos clips de áudio em todo o seu conjunto de dados pode ser benéfico para o treino de modelos.

💡 Dica do professor:

**Dica de gravação para alunos:** A Teachable Machine extrai amostras em janelas de 1 ou 2 segundos, dependendo das suas definições. Para alcançar alta precisão, grave pelo menos 20 a 30 amostras distintas por aula. Se estiver a treinar o modelo para reconhecer uma palavra específica (como "olá"), peça aos alunos para repetir a palavra em diferentes tons, velocidades e volumes dentro desses clipes.

- **Organização dos dados:** Organize os seus ficheiros de áudio em pastas correspondentes às classes definidas na Teachable Machine. Crie uma pasta separada para cada aula e coloque as amostras de áudio relevantes nessa pasta. Esta estrutura de pastas facilita o upload dos seus dados para a Teachable Machine, pois normalmente pode carregar pastas inteiras de uma só vez. Use convenções claras e consistentes de nomes para os seus ficheiros de áudio para garantir uma organização lógica.
- **Limpeza de dados:** Antes de carregar, reserve algum tempo para rever e limpar o seu conjunto de dados de áudio. Remova quaisquer ficheiros de áudio que sejam irrelevantes, inadequados, corrompidos ou excessivamente ruidosos. Se necessário, edite o áudio para melhorar a qualidade ou consistência (por exemplo, removendo silêncios prolongados, normalizando o volume). Certifique-se de que a clareza do áudio é fundamental.
- **Divisão de Dados (opcional, mas recomendado):** Para práticas mais avançadas de Aprendizagem Automática, recomenda-se dividir o seu conjunto de dados em três subconjuntos:
    - **Conjunto de treino:** O maior subconjunto, usado para treinar o modelo de ML.
    - **Conjunto de validação:** usado para avaliar o desempenho do modelo durante o treino e ajustar os hiperparâmetros.
    - **Conjunto de teste:** Usado para avaliar o desempenho do modelo final após a conclusão do treino. O Teachable Machine não requer divisão explícita para uso básico, mas é uma boa prática para avaliação rigorosa do modelo. Obtém-se um efeito semelhante ao reservar uma parte dos seus dados e não a usar durante a fase inicial de treino. Se optar por dividir os dados, certifique-se de que a distribuição das classes é semelhante entre todos os subconjuntos.
- **Carregar dados para a Teachable Machine:** Assim que os seus dados estão preparados, estão prontos para serem carregados na Teachable Machine. A plataforma fornece ferramentas intuitivas para carregar áudio, permitindo-lhe tipicamente:
    - Gravar áudio diretamente usando o teu microfone.
    - Carregar ficheiros de áudio do seu computador. Siga as instruções no ecrã para carregar os seus dados e associá-los às classes corretas.

Ao preparar cuidadosamente os seus dados, garante que estão nas condições ideais para treinar o seu projeto áudio na Teachable Machine, levando a um melhor desempenho do modelo e resultados mais fiáveis.

💡 Dica do professor:

**Estratégia de gestão da sala de aula: Prevenir a 'contágio sonoro':** Para evitar interferências acústicas (quando a voz de um grupo é gravada no modelo de outro), organize a sala usando uma das seguintes duas estratégias:

- **Estações de gravação:** Instale estações de gravação específicas em diferentes cantos da sala de aula ou no corredor.
- **Fluxo de trabalho escalonado:** Divida a turma de modo que metade dos alunos trabalhe nas definições, etiquetas e documentação da turma, enquanto a outra metade grava amostras de áudio por turnos.

## 4.3 Treino e Avaliação de Modelos: Dar Vida à Sua IA de Áudio

### 4.3.1 Treinar o seu modelo áudio: passo a passo

Depois de preparar o seu conjunto de dados áudio, o passo seguinte envolve treinar o seu modelo de Aprendizagem Automática no Teachable Machine. Este processo de treino consiste em introduzir os seus dados áudio no modelo, permitindo-lhe aprender e reconhecer os padrões e características que distinguem as diferentes classes sonoras que definiu. O Teachable Machine simplifica este processo, tornando-o acessível mesmo para quem não tem experiência em programação. Aqui está um guia passo a passo para treinar o seu modelo áudio:

- **Vai ao teu projeto:** Abre a Máquina Teachable e vai ao projeto de áudio em que tens trabalhado. Certifica-te de que os teus dados de áudio estão carregados e organizados nas turmas corretas.
- **Analise os seus dados:** Antes de iniciar o processo de formação, reserve um momento para analisar os seus dados. Confirme a sua precisão e certifique-se de que cada aula contém um número suficiente de amostras de áudio representativas. Normalmente, pode ouvir as amostras de áudio de cada aula diretamente na interface da Teachable Machine. Preste atenção ao ruído de fundo ou a quaisquer inconsistências.
- **Iniciar treino:** A Teachable Machine fornece um botão ou comando claro para iniciar o processo de treino. Este é um botão claramente visível, normalmente intitulado "Model Train". Clique neste botão para iniciar o treino.
- **Processo de treino:** Uma vez iniciado o treino, a Teachable Machine começa a processar os seus dados áudio. A plataforma utiliza algoritmos de Aprendizagem Automática para analisar o áudio e identificar características-chave que distinguem as diferentes classes. Durante o treino, o modelo ajusta os seus parâmetros internos para otimizar a sua

capacidade de classificar corretamente os sons. A Teachable Machine fornece feedback visual sobre o progresso do treino. Isto inclui barras de progresso, mensagens ou animações que indicam que o treino está em curso. A duração do processo de treino depende do tamanho e complexidade do seu conjunto de dados, bem como do poder de processamento do seu computador ou dos servidores da plataforma.

- **Não é necessária programação:** Uma vantagem fundamental do Teachable Machine é a forma como gere cálculos complexos de treino de modelos em segundo plano. Não precisa de escrever código nem de ter conhecimentos especializados de algoritmos de Machine Learning para treinar o seu modelo.
- **Definições Avançadas de Treino (opcionais para exploração adicional):** Embora tenha sido concebida para ser simples, a Teachable Machine oferece "Definições Avançadas" que permitem aos utilizadores afinar o processo de treino. Estas definições podem influenciar a forma como o modelo aprende e o seu desempenho final. A disponibilidade e a natureza específica destas definições podem variar ligeiramente com as atualizações da plataforma Teachable Machine.
    - **Estações:** Uma representa uma passagem completa por todo o conjunto de dados de treino durante o processo de treino. Aumentar o número de estações geralmente permite uma aprendizagem mais aprofundada, mas também aumenta o risco de sobreajuste (onde o modelo tem bom desempenho em dados de treino mas tem um desempenho fraco em dados novos). O Teachable Machine permite o ajuste das estações, dando-lhe controlo sobre a duração do treino.
    - **Tamanho do lote:** Isto refere-se ao número de amostras de dados (clipes de áudio, neste caso) que o modelo processa de cada vez durante cada atualização de parâmetro. Ajustar o tamanho do lote afeta a velocidade de treino e a dinâmica de aprendizagem. O Teachable Machine oferece opções para diferentes tamanhos de lote.
    - **Taxa de aprendizagem:** Um parâmetro crucial, a taxa de aprendizagem controla o tamanho do passo que o modelo realiza para atualizar os seus parâmetros com base no erro calculado (perda). Uma taxa de aprendizagem demasiado alta causa divergência e falha na aprendizagem, enquanto uma taxa demasiado baixa atrasa significativamente o processo de treino. Enquanto a Teachable Machine simplifica muitos aspetos, fluxos de trabalho avançados de aprendizagem automática envolvem esta taxa. Se estiver disponível como opção, avance com cautela.
    - **Outros hiperparâmetros:** Os modelos de aprendizagem automática têm parâmetros chamados hiperparâmetros que controlam o processo de aprendizagem. A Teachable Machine disponibiliza alguns destes parâmetros para

ajuste. A afinação destes frequentemente requer experimentação e compreensão dos princípios da aprendizagem automática.

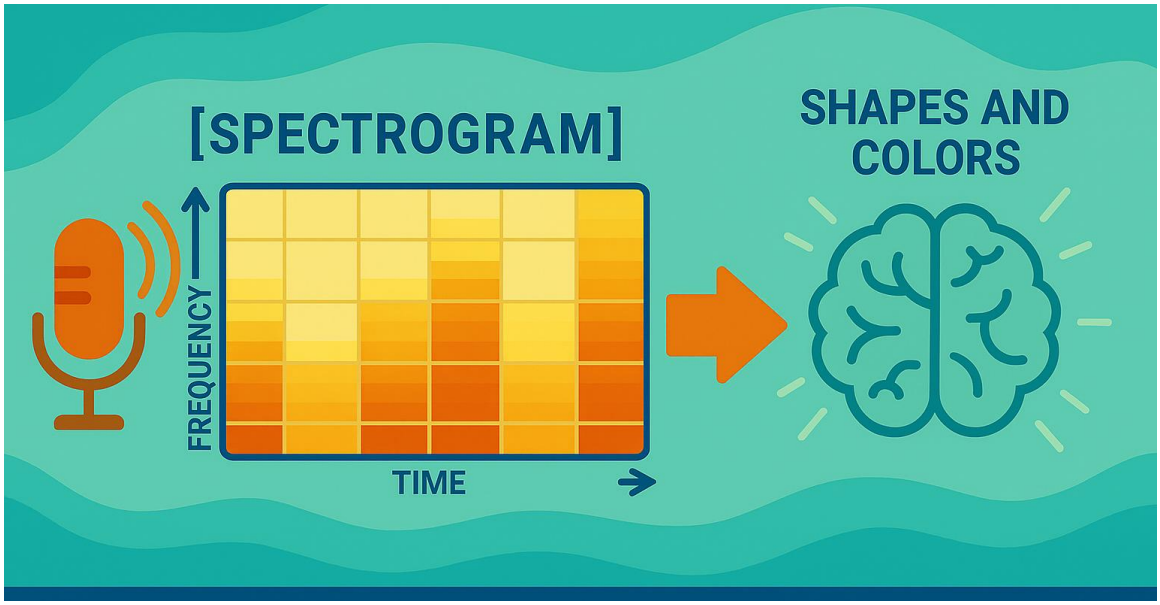
- **Utilização de definições avançadas:** Se optar por usar definições avançadas, recomenda-se geralmente uma abordagem sistemática. Mude uma definição de cada vez, observe o seu impacto no desempenho do modelo e acompanhe meticulosamente os experimentos e resultados. A utilização eficaz requer frequentemente uma compreensão mais profunda dos conceitos de aprendizagem automática. Para quem é novo na aprendizagem automática, é aconselhável começar pelas definições pré-definidas e explorar gradualmente as opções avançadas à medida que ganha experiência.

- **Dicas de treino:**
  - **Comece com dados suficientes:** Certifique-se de que há dados adequados em cada aula antes do treino. Um conjunto de dados equilibrado, com um número razoável de amostras áudio por turma, geralmente produz melhores resultados.
  - **Acompanhar o progresso (se disponível):** Se a Teachable Machine fornecer feedback sobre o progresso dos treinos, acompanhe-o para perceber como o modelo aprende.
  - **Treino iterativo:** Pode ser necessário treinar o modelo várias vezes, especialmente se os resultados iniciais forem insatisfatórios. Ajuste o seu conjunto de dados, adicione mais dados ou modifique classes e depois retreine o modelo.
- **Formação Concluída:** Assim que o processo de formação estiver concluído, a Teachable Machine notifica-o. O seu modelo de reconhecimento áudio está agora treinado e pronto para avaliação e utilização.

O Teachable Machine simplifica o processo de treino, tornando-o acessível a uma vasta gama de utilizadores. Ao seguir estes passos e garantir um conjunto de dados bem preparado, treina eficazmente o seu modelo áudio e começa a explorar as suas capacidades.

**Como Funciona o Reconhecimento de Áudio (Simplificado):**

A aprendizagem automática para áudio funciona transformando o som num mapa visual de frequências chamado espectrograma. O sistema deteta formas e cores neste mapa para identificar padrões únicos para cada som.




| 🧠 Processo simplificado | | | | |
|---|---|---|---|---|
| 1. Gravar samples | 2. Converter para espectrogramas | 3. Comboio Modelo | 4. Testar novos sons | 5. Melhorar com Feedback |

Os professores podem mostrar como a variação do volume, do ruído de fundo ou da distância do microfone afeta os resultados. Isto ajuda os alunos a perceber porque é importante ter dados controlados e variados.

📝 Nota de paciência:

**Atividade no separador do navegador:** O processamento de dados de áudio espectrográfico requer mais potência computacional do que os arrays de imagens padrão. Certifique-se de que os aprendentes mantêm o separador do navegador Teachable Machine ativo e visível no ecrã durante o treino. Se minimizarem a janela ou mudarem para outro separador do navegador, o processo de treino irá abrandar ou ser completamente interrompido[.

### 4.3.2 Avaliação do Desempenho do Modelo: Compreensão da Precisão e Métricas

Depois de treinar o seu modelo áudio na Teachable Machine, avaliar o seu desempenho é crucial para determinar se funciona bem e cumpre os critérios de sucesso do seu projeto. A avaliação envolve testar o modelo com dados áudio que não ouviu durante o treino e analisar as suas previsões. Aqui está um guia para avaliar o desempenho do modelo em projetos áudio:

- **Teachable Machine Preview:** Uma funcionalidade de pré-visualização integrada no Teachable Machine permite-lhe testar rapidamente o seu modelo treinado. Pode usar o seu microfone para fornecer novos dados de áudio ou carregar ficheiros de áudio existentes, e depois observar como o modelo os classifica. Esta pré-visualização oferece uma forma intuitiva de avaliar rapidamente o desempenho do seu modelo. Observe se o modelo identifica corretamente os sons ou padrões de voz no áudio fornecido. Preste atenção a quaisquer classificações erradas ou situações em que o modelo pareça incerto.
- **Compreenda a precisão:** A precisão é uma métrica comum para avaliar modelos de classificação. Representa a proporção global de previsões corretas feitas pelo modelo. Por exemplo, se fornecer ao modelo 100 excertos áudio de teste e o modelo obtiver corretamente 90%, a precisão é de 90%. Embora a precisão seja uma métrica útil, é importante estar ciente das suas limitações, especialmente com conjuntos de dados desequilibrados (onde algumas turmas têm significativamente mais dados do que outras).
- **Matriz de confusão:** Uma matriz de confusão fornece uma análise mais detalhada do desempenho do seu modelo. Esta tabela mostra o número de previsões corretas e incorretas para cada classe. As linhas normalmente representam as classes reais, enquanto as colunas representam as classes previstas. Analisar a matriz de confusão ajuda a identificar que classes o modelo tem dificuldade em distinguir e onde comete mais erros.
- **Precisão e recordação (simplificada):** Outras métricas importantes, precisão e recordação, dão-lhe uma compreensão mais aprofundada do desempenho do seu modelo, especialmente com conjuntos de dados desequilibrados.
    - **Precisão:** mede a proporção de identificações positivas que estavam realmente corretas. Responde à pergunta: "De todas as vezes em que o modelo indicou que era uma determinada classe, com que frequência acertou?"
    - **Recordação:** Mede a proporção de casos positivos reais que foram corretamente identificados pelo modelo. Responde à seguinte pergunta: "De todas as vezes em que foi *realmente* uma determinada classe, com que frequência o modelo a indicou?" Uma pontuação de precisão elevada indica que o modelo se destaca na prevenção de falsos positivos, enquanto uma pontuação elevada na recordação

significa que é eficaz na identificação de todos os casos de uma determinada classe.

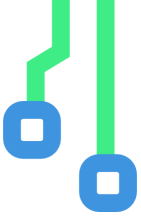
- **Pontuação F1 (simplificada):** A pontuação F1 combina precisão e recordação num único valor. Fornece uma medida equilibrada do desempenho de um modelo, especialmente quando existe um desequilíbrio entre classes. Geralmente, uma pontuação F1 mais alta indica melhor desempenho.
- **Melhores práticas de avaliação:**
    - **Use um conjunto de testes separado:** Para uma avaliação imparcial, é crucial testar o seu modelo com dados que não encontrou durante o treino. Isto é conhecido como conjunto de testes.
    - **Avalie com base em dados representativos:** Certifique-se de que os seus dados de teste representam com precisão o áudio real que o seu modelo irá encontrar.
    - **Considere os objetivos do seu projeto:** As métricas mais importantes para avaliar o seu modelo dependem dos objetivos específicos do projeto. Se evitar falsos positivos for fundamental (por exemplo, num sistema de alerta de segurança), priorize a precisão. Se identificar todas as instâncias de uma classe for crucial (por exemplo, num sistema de diagnóstico médico), priorize a recuperação.
    - **Avaliação iterativa:** A avaliação é um processo iterativo. Pode ser necessário avaliar o seu modelo várias vezes, ajustar o seu conjunto de dados ou processo de treino, e depois reavaliar para ver se as alterações melhoraram o desempenho.

Ao avaliar cuidadosamente o desempenho do seu modelo usando métricas e boas práticas adequadas, ganha uma compreensão clara dos seus pontos fortes e fracos e toma decisões informadas sobre como o melhorar.

### 4.3.3 Resolução de problemas e melhoria do seu modelo

É comum encontrar desafios e áreas de melhoria ao treinar e avaliar o seu projeto áudio Teachable Machine. O seu modelo pode não funcionar inicialmente como esperado, ou pode notar fraquezas específicas nas suas previsões. A resolução de problemas e a melhoria iterativa do seu modelo são partes essenciais do processo de aprendizagem automática. Aqui está um guia para o ajudar:

- **Identifique os problemas comuns:**
    - **Baixa precisão:** O modelo faz um grande número de previsões incorretas.
    - **Overfit:** O modelo tem bom desempenho em dados de treino, mas tem um desempenho fraco em dados novos e nunca antes vistos. Isto indica que o modelo aprendeu demasiado bem os dados de treino, incluindo ruído e as suas peculiaridades.



- **Confusão entre classes:** O modelo tem dificuldade em distinguir entre certas classes, frequentemente classificando mal o áudio de uma classe como pertencente a outra. Isto é comum quando os sons são muito semelhantes.
- **Enviesamento:** O modelo tem um desempenho significativamente melhor em alguns grupos ou categorias (por exemplo, certos acentos, instrumentos específicos) do que noutras, o que indica um potencial viés nos dados ou modelo.

- **Estratégias para resolução de problemas e melhoria:**
  - **Aumentar a quantidade de dados:** Se o seu modelo tiver baixa precisão, aumentar a quantidade de dados de treino é uma solução comum. Recolha mais amostras de áudio para cada classe, garantindo um conjunto de dados equilibrado. Um conjunto de dados maior fornece ao modelo mais informação para aprender, melhorando a sua capacidade de generalização.
  - **Melhorar a qualidade e diversidade dos dados:** Analise os dados existentes para identificar quaisquer amostras de áudio de baixa qualidade ou não representativas. Remova gravações com ruído de fundo excessivo, distorção ou irrelevância. Aumente a diversidade do seu conjunto de dados capturando áudio de diferentes fontes, em vários ambientes acústicos e com diferentes dispositivos de gravação. Aplique técnicas de aumento de áudio para aumentar artificialmente a diversidade de dados.
  - **Refina as tuas classes:** Se o teu modelo confundir certas classes, revê as definições de classes para garantir clareza e distinção. Se necessário, junta classes semelhantes ou cria subclasses mais específicas para reduzir ambiguidades. Certifica-te de que as amostras de áudio dentro de cada classe são representativas e não se sobrepõem significativamente a outras classes.
  - **Abordar o overfit:** Quando o seu modelo está a experienciar overfit, considere estas abordagens:
    - **Aumento de dados:** Como mencionado anteriormente, o aumento de dados ajuda a prevenir o sobreajuste.
    - **Simplificar o modelo (se aplicável):** Embora o Teachable Machine abstraia grande parte da arquitetura do modelo, em ML mais avançado, simplificar o modelo por vezes ajuda a resolver o overfit.
    - **Paragem precoce (se disponível):** Alguns sistemas de treino incorporam 'paragem antecipada', onde o treino é interrompido quando o desempenho num conjunto de validação começa a deteriorar-se.
  - **Verifique a existência de viés:** Analise cuidadosamente o seu conjunto de dados para identificar potenciais fontes de viés. Certifique-se de que os seus dados representam a variedade de sons ou vozes que o seu modelo pretende processar.

Se for identificado algum viés (por exemplo, baixo desempenho em certos sotaques), recolha dados mais diversos para equilibrar o seu conjunto de dados e mitigar o viés. Avalie o desempenho do seu modelo em diferentes grupos e categorias para identificar e corrigir quaisquer disparidades.

- **Treino e avaliação iterativos:** A resolução e melhoria de problemas são processos iterativos. Faça pequenas alterações ao seu conjunto de dados, processo de treino ou definições de classes, depois reforme e reavalie o seu modelo. Acompanhe meticulosamente as alterações feitas e o seu impacto no desempenho. Use métricas de avaliação (precisão, exatidão, recordação, matriz de confusão) para orientar as suas melhorias.
- **Procure ajuda e recursos:** Se estiver a ter dificuldades em melhorar o desempenho do seu modelo, não hesite em procurar ajuda e recursos. Fóruns online, tutoriais e comunidades oferecem informações e orientações valiosas. A documentação e os recursos de suporte da Teachable Machine também fornecem dicas e conselhos úteis para resolução de problemas.

Ao resolver problemas sistematicamente e melhorar iterativamente o seu modelo, supera desafios, melhora o seu desempenho e alcança os resultados desejados nos seus projetos de áudio na Teachable Machine.

## 4.4 Aplicações na Sala de Aula: IA de Áudio em Ação

### 4.4.1 Atividades de aprendizagem interativas com reconhecimento áudio

A tecnologia de reconhecimento áudio, desenvolvida pela Teachable Machine, serve como uma ferramenta valiosa para criar atividades de aprendizagem envolventes e interativas na sala de aula. Incorporar IA baseada em áudio nas suas aulas proporciona aos alunos experiências práticas, melhora a sua compreensão dos conceitos relacionados com o som e promove um ambiente de aprendizagem mais dinâmico. Aqui estão alguns exemplos de atividades de aprendizagem interativas com reconhecimento áudio:

- **Caças ao tesouro sonoras:** Desenhe uma atividade de caça ao tesouro onde os alunos utilizem um modelo de Teachable Machine para identificar sons específicos na sala de aula, escola ou num ambiente exterior. Os alunos podem usar um tablet ou smartphone equipado com o modelo da Teachable Machine para "ouvir" o ambiente à sua volta procurando sons designados. Esta atividade promove competências de escuta ativa, incentiva a exploração dos ambientes acústicos e torna a aprendizagem mais envolvente. Por exemplo, os alunos mais novos podem procurar sons de diferentes animais, veículos

ou instrumentos musicais, enquanto os alunos mais velhos podem identificar sons distintos de diferentes materiais ou processos num laboratório de ciências.

- **Prática interativa de pronúncia:** Desenvolva uma ferramenta interativa de pronúncia onde os aprendentes pratiquem a pronúncia de palavras ou frases numa língua-alvo. Um modelo de Teachable Machine pode ser treinado para reconhecer a pronúncia correta, fornecendo feedback imediato. Isto permite que os alunos aperfeiçoem as suas competências de fala de forma independente, tornando a aprendizagem de línguas mais dinâmica e personalizada. Por exemplo, os aprendizes gravam-se a dizer uma palavra, e o modelo indica se a pronúncia está correta ou sugere coisas a melhorar.
- **Jogos de correspondência** de sons**:** Criar jogos de correspondência sonora é uma forma eficaz de fortalecer as competências de discriminação e classificação auditiva. Estes jogos envolvem os alunos a associar um som ouvido à sua imagem, palavra ou categoria correspondente, usando o modelo da Teachable Machine. Isto é particularmente útil na música (associar sons de instrumentos a imagens de instrumentos) ou na ciência (associar sons de animais a imagens de animais). A natureza interativa proporciona feedback imediato, tornando a aprendizagem agradável.
- **Narrativa baseada em áudio e escrita criativa:** O reconhecimento áudio pode estimular a criatividade e as atividades de contar histórias. Os alunos podem usar um modelo de Teachable Machine para ativar diferentes efeitos sonoros ou pistas musicais baseadas em palavras faladas, sons ambientais ou até as suas próprias vocalizações, permitindo a criação de paisagens sonoras interativas ou experiências narrativas enriquecedoras. Esta atividade estimula a imaginação, as competências linguísticas e narrativas dos alunos, promovendo a expressão multimodal. Por exemplo, os alunos podem criar uma história onde palavras específicas ativam efeitos sonoros associados, imergindo os ouvintes na narrativa.
- **Monitorização de sons ambientais:** Os alunos podem desenvolver projetos que monitorizem e classifiquem sons ambientais na sala de aula ou em locais específicos. Isto pode envolver a identificação de sons como 'porta a abrir', 'toque da campainha' ou 'momento de leitura silenciosa'. Esta atividade ensina os alunos sobre paisagens sonoras, recolha de dados e como a IA pode ser usada para monitorização e organização.
- **Composição e Exploração Musical:** Envolver os alunos em atividades básicas de composição ou exploração musical. Um modelo da Teachable Machine pode ser treinado para reconhecer vocalizações simples ou sons de instrumentos e depois ativar diferentes notas ou melodias musicais. Isto permite aos alunos experimentar com o som e compreender os princípios básicos da teoria musical através da interação.

Estas atividades de aprendizagem interativas demonstram o potencial do reconhecimento áudio para transformar a experiência em sala de aula, tornando-a mais envolvente, interativa e eficaz.

### 4.4.2 Integração de IA áudio em aulas específicas por disciplina

As capacidades de reconhecimento áudio da Teachable Machine integram-se perfeitamente numa vasta gama de aulas específicas por disciplina, enriquecendo o currículo e proporcionando aos alunos experiências de aprendizagem únicas. Ao adaptar projetos de IA de áudio a disciplinas específicas, os educadores aumentam o envolvimento dos alunos, promovem uma compreensão mais profunda e promovem a aprendizagem interdisciplinar. Aqui estão alguns exemplos de como integrar IA de áudio em diferentes disciplinas do ensino básico:

- **Música e Artes Performativas:**
  - **Identificação de instrumentos:** Podem ser desenvolvidos projetos que classifiquem diferentes instrumentos musicais a partir de gravações. Os alunos analisam peças musicais, utilizando reconhecimento áudio para identificar os instrumentos tocados, as suas funções ou arranjos orquestrais. Isto melhora a apreciação musical e desenvolve as competências de escuta.
  - **Classificação de géneros musicais:** Crie projetos que classifiquem peças musicais com base no seu género, estilo ou instrumentação. Os alunos analisam gravações para identificar características musicais e categorizá-las. O reconhecimento áudio apoia a exploração da história da música, a análise de tendências musicais ou a criação de questionários interativos musicais.
  - **Análise de melodia e ritmo:** Podem ser desenvolvidos projetos que analisem e comparem diferentes melodias ou padrões rítmicos. Os alunos gravam ou analisam frases musicais, usando reconhecimento áudio para identificar contornos melódicos, variações rítmicas ou estruturas musicais. Isto contribui para a composição musical, improvisação ou interpretação.
- **Língua e Comunicação:**
  - **Prática de pronúncia:** Podem ser desenvolvidos projetos altamente eficazes para ajudar os alunos com a pronúncia em línguas estrangeiras ou até palavras complexas na sua língua materna. Os alunos gravam-se a pronunciar palavras ou expressões, e o modelo Teachable Machine fornece feedback imediato sobre se a sua pronúncia corresponde a um exemplo correto. Isto promove a prática autónoma e melhora a fluência oral.
  - **Análise dos padrões de fala:** Os projetos podem ser concebidos para analisar padrões na fala, como altura, ritmo ou entoação. Isto é valioso para compreender a

leitura dramática, a oratória em público ou diferentes formas de comunicação verbal.

- **Projetos de história oral:** Crie projetos que envolvam a gravação e análise de histórias orais. Os alunos utilizam o reconhecimento áudio para transcrever entrevistas, identificar temas-chave ou analisar narrativas individuais ou comunitárias. Isto preserva o património cultural, promove a aprendizagem intergeracional ou apoia a investigação comunitária.

- **Ciências do Ambiente e da Vida:**
  - **Vocalizações animais:** Podem ser criados projetos que classifiquem diferentes vocalizações animais (por exemplo, cantos de aves, croaxar de rãs, sons de insetos) em vários ecossistemas. Os alunos recolhem gravações de sons de animais na natureza ou utilizam áudio existente de documentários ou bases de dados online. O reconhecimento áudio ajuda a identificar diferentes espécies, analisar a comunicação animal ou estudar a biodiversidade.
  - **Monitorização do ruído ambiental:** Podem ser desenvolvidos projetos que monitorizem e analisem a poluição sonora ambiental. Os alunos gravam sons na sua comunidade e utilizam o reconhecimento áudio para identificar fontes de poluição sonora, medir níveis de ruído ou avaliar o impacto do ruído no ambiente. Isto aumenta a consciencialização sobre questões ambientais e promove soluções para a redução do ruído.
- **Ciência do som (Física):**
  - **Análise de ondas sonoras:** Podem ser realizados projetos que classifiquem diferentes tipos de ondas sonoras com base na frequência ou amplitude. Os alunos gravam sons de várias fontes (por exemplo, diapasões, instrumentos musicais) e analisam as suas formas de onda. O reconhecimento sonoro ajuda a visualizar ondas sonoras, explorar conceitos como ressonância ou estudar as propriedades do som.

Estes exemplos ilustram a versatilidade da IA de áudio na educação, demonstrando a sua adaptabilidade para melhorar a aprendizagem em múltiplas disciplinas. A integração de projetos áudio Teachable Machine em aulas específicas permite aos educadores criar experiências de aprendizagem envolventes, interativas e eficazes para os seus alunos.

**Tabela resumida: Visão geral dos projetos áudio interdisciplinares:**

| Disciplina | Ideia de Projeto de Sala de Aula | Objetivo de Aprendizagem |
|---|---|---|
| Música e Artes Performativas | Distinguir os sons do violino, flauta, piano e percussão. | Desenvolver a discriminação auditiva e o reconhecimento do timbre dos instrumentos. |
| Língua e Comunicação | Treine um modelo para reconhecer a pronúncia correta em comparação com erros fonéticos comuns. | Fornecer feedback automatizado e em tempo real sobre fonética e sotaques. |
| Ciências da Vida e do Ambiente | Classificar os cantos das aves locais ou monitorizar os níveis de ruído ambiental. | Estude a bioacústica, habitats e poluição sonora na comunidade. |
| Ciências do Som (Física) | Gravação de ondas sonoras resultantes do impacto entre madeira e metal ou entre diferentes diapasões | Analise a frequência das ondas sonoras, o tom e a densidade do material. |

### 4.4.3 Estratégias de avaliação utilizando projetos de IA baseados em áudio

Os projetos de IA baseados em áudio, criados com a Teachable Machine, servem como ferramentas valiosas para várias estratégias de avaliação destinadas a avaliar a aprendizagem dos alunos, fornecer feedback e acompanhar o progresso, especialmente no que diz respeito às competências de escuta e comunicação oral. Estes projetos oferecem oportunidades únicas para avaliação autêntica, permitindo aos alunos demonstrar compreensão e competências de forma prática e envolvente. Aqui estão alguns exemplos de estratégias de avaliação usando projetos de IA baseados em áudio:

- **Avaliação baseada em projetos:** Atribuir projetos de IA baseados em áudio como principal tarefa de avaliação exige que os alunos desenhem, desenvolvam e avaliem os seus próprios modelos de reconhecimento sonoro ou de fala. Avalie a compreensão dos alunos sobre os conceitos e competências envolvidos, como recolha de dados (gravação), treino de modelos, avaliação e aplicação. Avalie a qualidade dos seus projetos, incluindo a precisão, funcionalidade e criatividade dos modelos. Proporcione oportunidades para os alunos apresentarem os seus designs, explicando as suas escolhas de design e as conclusões a que chegaram. A avaliação baseada em projetos permite uma avaliação

holística da aprendizagem dos alunos e proporciona-lhes um sentido de propriedade do seu trabalho.

- **Avaliação Baseada no Desempenho (Pronúncia/Competências de Escuta):** A utilização de projetos de IA baseados em áudio permite-lhe avaliar a capacidade dos aprendizes aplicarem conhecimentos e competências em situações práticas relacionadas com o som. Apresente aos alunos cenários ou desafios que exigam que utilizem os seus modelos para tarefas específicas de escuta. Avalie o seu desempenho com base na precisão e eficácia das previsões do modelo, bem como na sua capacidade de interpretar e utilizar os resultados. Por exemplo, os alunos podem usar um modelo para autoavaliar a pronúncia de palavras complexas ou demonstrar a sua capacidade de classificar sons ambientais.
- **Avaliação formativa:** Projetos de IA baseados em áudio podem ser integrados em atividades de avaliação formativa para acompanhar a aprendizagem dos alunos e fornecer feedback contínuo. Use modelos do Teachable Machine para criar questionários interativos, jogos ou atividades que permitam aos alunos verificar a sua compreensão de conceitos relacionados com o som ou praticar competências específicas de escuta. Forneça aos alunos feedback imediato sobre as suas respostas, identificando áreas que necessitam de apoio adicional. A avaliação formativa com IA de áudio ajuda os alunos a acompanhar o seu progresso e a identificar áreas a melhorar.
- **Autoavaliação e avaliação entre pares:** Incentive os alunos a utilizarem projetos de IA baseados em áudio para autoavaliação e avaliação entre pares. Isto promove metacognição, pensamento crítico e competências de colaboração. Os alunos utilizam os seus modelos para avaliar a sua própria compreensão dos sons ou padrões vocais, ou para dar feedback aos colegas nos seus projetos áudio. Fornecer aos alunos critérios e diretrizes claros para autoavaliação e avaliação entre pares.
- **Avaliação do portefólio:** Inclua projetos de IA baseados em áudio nos portefólios dos alunos para mostrar o seu aprendizado e conquistas ao longo do tempo. Os portefólios oferecem uma visão abrangente do crescimento e desenvolvimento dos alunos, destacando pontos fortes, competências e progresso nas áreas auditiva e relacionada com IA. Os alunos escolhem os seus melhores projetos para inclusão e refletem sobre as suas experiências de aprendizagem.

Exemplos de tarefas de avaliação para projetos áudio:

- "Desenhar um modelo de reconhecimento áudio que classifique diferentes instrumentos musicais e o utilize para identificar instrumentos numa peça curta de música."
- "Desenvolver um questionário baseado em áudio que teste o conhecimento dos alunos sobre os sons dos animais e os seus habitats."

- "Criar uma avaliação baseada no desempenho em que os alunos utilizem um modelo de reconhecimento áudio para demonstrar a pronúncia correta de dez novas palavras de vocabulário em espanhol."
- "Use um modelo de Teachable Machine para criar uma atividade interativa que ajude os alunos a distinguir entre diferentes formas de expressão vocal (por exemplo, tom alegre, triste ou interrogativo)."

Ao incorporar projetos de IA baseados em áudio numa variedade de estratégias de avaliação, os educadores criam formas autênticas, envolventes e eficazes de avaliar a aprendizagem dos alunos e promover uma compreensão mais profunda em matérias relacionadas com a audição.

# Módulo 5: Criação de Designs de Poses

Este módulo apresenta-lhe os Projetos de Postura na Teachable Machine. É importante notar que trabalhar com reconhecimento de postura pode ser mais complexo do que projetos de imagem ou áudio. Considere este módulo uma opção avançada, que deve ser explorada depois de ganhar confiança e experiência com Projetos de Imagem e Áudio. Os Projetos de Postura permitem a criação de modelos de Aprendizagem Automática que reconhecem e classificam diferentes posturas e movimentos corporais.

## 5.1 Planeamento de projetos: Definir a sua IA baseada em poses

Um planeamento cuidadoso continua a ser essencial para qualquer projeto de Teachable Machine, e os Projetos de Postura não são exceção. Definir o âmbito do seu projeto, identificar aplicações adequadas e estabelecer critérios claros de sucesso criam o terreno para um desenvolvimento eficaz.

### 5.1.1 Identificar aplicações em sala de aula para reconhecimento de poses

O reconhecimento de posturas, impulsionado por Aprendizagem Automática, oferece possibilidades interativas únicas para melhorar a aprendizagem física e observacional na sala de aula. Esta tecnologia cria oportunidades para atividades baseadas no movimento, facilita a automação de interfaces controladas por gestos e ajuda os alunos a compreender a linguagem corporal ou expressões físicas. Aqui estão alguns exemplos de aplicações em sala de aula para o reconhecimento de posturas:

- **Educação física e análise do movimento:** O reconhecimento de poses revela-se inestimável para criar ferramentas que ajudam os alunos a identificar e classificar diferentes exercícios físicos, passos de dança ou posturas de yoga. Os alunos, por exemplo, podem treinar um modelo para reconhecer se estão a executar corretamente um polichinelo ou a manter uma postura de dança específica. Esta aplicação oferece feedback imediato, promovendo a forma e técnica corretas.
- **Jogos de aprendizagem interativos:** Integrar o reconhecimento de poses em jogos interativos pode tornar a aprendizagem altamente envolvente e fisicamente ativa. Os professores, por exemplo, podem criar um jogo onde os alunos assumem posturas específicas para responder a perguntas ou navegar num ambiente digital. Isto acrescenta uma dimensão cinética à aprendizagem, destinada a alunos cinestésicos.
- **Narrativa e teatro:** O reconhecimento de poses pode enriquecer as artes criativas e a narrativa ao permitir que os alunos desencadeem eventos ou ações numa narrativa digital através dos seus movimentos corporais. Os alunos podem usar um modelo de Teachable Machine para avançar numa história enquanto representam diferentes poses ou gestos

das personagens. Isto estimula a imaginação, a expressão física e as competências de contar histórias.

- **Tecnologias assistivas e movimento inclusivo:** Ferramentas concebidas para ajudar alunos com limitações físicas ou necessidades especiais podem ser desenvolvidas usando o reconhecimento de posturas. Um projeto, por exemplo, pode ajudar um aluno a praticar exercícios terapêuticos específicos fornecendo feedback sobre a sua postura ou auxiliando na comunicação através de gestos reconhecidos. Esta aplicação promove a inclusão e oferece apoio personalizado para atividades físicas.
- **Competências de observação nas ciências ou ciências sociais:** Os alunos podem criar projetos que observem e classifiquem linguagem corporal específica ou interações sociais (por exemplo, identificando posturas que indicam felicidade, tristeza ou confusão a partir de um conjunto controlado de exemplos). Isto introduz conceitos básicos de análise da comunicação não verbal.

Estes exemplos representam apenas algumas das muitas aplicações do reconhecimento de poses na sala de aula. As possibilidades são vastas, limitadas apenas pela criatividade e engenho de educadores e alunos, e por uma cuidadosa consideração dos limites éticos.

### 5.1.2 Escolha de Posturas ou Movimentos Adequados para Classificação

Selecionar as posturas ou movimentos certos para o seu Projeto de Poses é crucial para garantir o seu sucesso e valor educativo. As suas escolhas influenciam diretamente a complexidade do projeto, a viabilidade da recolha de dados e a sua relevância para os seus objetivos de aprendizagem. Aqui estão algumas considerações chave para escolher poses ou movimentos adequados para avaliação na Teachable Machine:

- **Simplicidade e distinguibilidade:** Comece com posturas ou movimentos que sejam claramente distintos e fáceis de diferenciar. Evite categorias que sejam demasiado semelhantes ou envolvam nuances subtis, pois são difíceis para o modelo aprender com precisão. Por exemplo, em vez de tentar distinguir entre gestos com as mãos ligeiramente diferentes (o que pode ser desafiante), comece por algo mais simples, como avaliar movimentos gerais (por exemplo, 'em pé', 'sentado', 'levantar a mão'). À medida que os alunos ganham experiência, podem gradualmente avançar para tarefas de avaliação mais complexas.
- **Relevância para os objetivos de aprendizagem:** Escolha posturas ou movimentos que estejam diretamente alinhados com os seus objetivos específicos de aprendizagem e com os objetivos curriculares. Selecione categorias que ajudem os alunos a adquirir novas informações, desenvolver competências específicas (por exemplo, competências motoras,

capacidades de observação) ou explorar tópicos relevantes. Por exemplo, numa aula de educação física, os alunos podem criar um projeto para classificar diferentes exercícios de aquecimento. Certifique-se de que o projeto apoia e melhora a experiência global de aprendizagem.

- **Viabilidade da recolha de dados:** Considere a facilidade e praticidade de recolher dados suficientes para as poses ou movimentos escolhidos. Selecione categorias para as quais possa obter facilmente um conjunto de dados diversificado e representativo usando uma webcam. As poses devem ser consistentemente reproduzíveis e facilmente visíveis pela câmara. Evite categorias que exijam configurações complexas, equipamento específico para além de uma webcam, ou poses difíceis de manter consistentemente.
- **Clareza sobre categorias:** Defina categorias claras e inequívocas para o seu projeto. Certifique-se de que existe uma sobreposição ou ambiguidade mínima entre estas categorias. Cada categoria deve representar uma pose ou movimento distinto e bem definido. Evite categorias que sejam demasiado amplas ou que possam ser facilmente confundidas entre si. Por exemplo, em vez de uma única categoria 'dança', opte por movimentos distintos como 'plié de ballet' e 'jazz square'.
- **Envolvimento e interesse dos alunos:** Escolha poses ou movimentos que possam envolver e despertar o interesse dos seus alunos. Selecione categorias que sejam relevantes para as suas atividades físicas, jogos ou interesses. O interesse dos alunos num projeto traduz-se frequentemente em maior motivação para participação e aprendizagem. Considere envolver os alunos no processo de seleção, fazer brainstorming de ideias em conjunto e permitir que escolham categorias apelativas.
- **Considerações éticas e privacidade:** Esteja sempre muito atento a quaisquer considerações éticas relacionadas com a recolha e utilização de dados de pose, especialmente ao trabalhar com estudantes. Assegure que é obtido o devido consentimento para gravações de vídeo. Priorize a privacidade dos alunos, assegurando que as gravações são usadas apenas para o seu propósito educativo e não são partilhadas de forma inadequada. Se possível, concentre-se em movimentos não identificáveis. Escolha categorias que promovam uma imagem corporal positiva e atividade física segura.

Ao considerar cuidadosamente estes fatores, escolha as poses ou movimentos adequados para os seus projetos de pose no Teachable Machine, garantindo que são educativos valiosos, envolventes e eticamente corretos.

### 5.1.3 Definição dos critérios de sucesso do projeto

Estabelecer critérios claros de sucesso antes de iniciar o seu projeto de posagem na Teachable Machine é crucial para avaliar a sua eficácia e determinar se atingiu o objetivo pretendido. Estes

critérios fornecem um parâmetro para medir o desempenho do seu projeto e identificar áreas a melhorar. Também o ajudam a manter o foco durante o processo de desenvolvimento e a garantir que se mantém no caminho certo para alcançar os seus objetivos. Aqui está um guia para definir critérios eficazes de sucesso para projetos de colocação:

- **Precisão e métricas de desempenho:** Definir objetivos para a precisão e desempenho do seu modelo de reconhecimento de poses é uma forma comum de definir sucesso.
    - **Precisão global:** Determinar a percentagem mínima aceitável de avaliações corretas. Por exemplo, um objetivo pode ser alcançar 85% de precisão global, o que significa que o modelo avalia corretamente 85% das poses apresentadas.
    - **Precisão específica da turma:** Para posturas mais críticas ou desafiantes (por exemplo, distinguir diferenças subtis nos exercícios físicos), podem ser definidos objetivos específicos de precisão para cada uma. Pode ser necessária maior precisão para identificar a forma correta num projeto de treino desportivo.
    - **Precisão e recordação (simplificada):** Estas métricas dão-lhe uma compreensão mais detalhada de quão bem o seu modelo está a funcionar. A precisão indica com que frequência o modelo estava correto quando dizia que uma pose pertencia a uma determinada classe. Recordar mede com que frequência o modelo identificou corretamente uma pose que *realmente* pertencia a uma determinada classe. Um modelo equilibrado normalmente tem um bom desempenho em ambos os aspetos.
    - **Tempo de resposta:** Se for necessário reconhecimento de poses em tempo real (por exemplo, para jogos interativos), defina um objetivo para o tempo máximo aceitável de resposta. Isto mede o tempo que o modelo demora a processar uma pose e a fornecer uma classificação.
- **Funcionalidade e usabilidade:** Defina critérios relacionados com a funcionalidade e usabilidade do seu projeto, especialmente se este tiver como alvo uma aplicação ou grupo de utilizadores específico.
    - **Facilidade de utilização:** Se o seu projeto inclui uma interface de utilizador, devem ser definidos critérios quanto à sua facilidade de utilização e intuitividade. Considere se os utilizadores conseguem interagir facilmente com o modelo e compreender os seus resultados.
    - **Integração:** Para projetos destinados à integração com outro sistema ou aplicação, defina critérios para uma integração bem-sucedida. Certifique-se de que o modelo se liga e troca dados com o outro sistema de forma fluida.
    - **Capacidade de resposta:** Avalie a fluidez com que o modelo segue e responde ao movimento humano.

- **Impacto educativo (se aplicável):** Para projetos concebidos com fins educativos, defina critérios relacionados com o seu impacto na aprendizagem dos alunos.
    - **Resultados de aprendizagem:** O projeto ajuda os alunos a alcançar os resultados de aprendizagem desejados? Os alunos conseguem demonstrar um aumento de conhecimentos ou competências após a utilização do projeto, como melhores competências motoras, compreensão da mecânica corporal ou capacidades de observação?
    - **Envolvimento:** O projeto envolve os alunos e motiva-os a aprender? Os alunos acham o projeto interessante e agradável?
    - **Feedback dos alunos:** Recolha feedback dos alunos sobre a sua experiência com o projeto. Acham útil, informativo ou agradável?
- **Requisitos técnicos:** Defina critérios relacionados com quaisquer requisitos técnicos específicos do seu projeto.
    - **Compatibilidade de plataformas:** O projeto funciona corretamente nas plataformas ou dispositivos pretendidos (por exemplo, webcams específicas, versões do navegador)?
    - **Robustez em termos de iluminação e fundo:** O modelo tem um bom desempenho em condições de iluminação variáveis ou contra diferentes fundos?
    - **Utilização de recursos:** O projeto utiliza os recursos de forma eficiente? Corre de forma fluida sem consumir excesso de poder de processamento ou memória?
- **Considerações éticas:** Incorpore considerações éticas nos seus critérios de sucesso.
    - **Proteção de privacidade:** O projeto protege a privacidade dos utilizadores e trata dados de pose de forma responsável, por exemplo, processando o vídeo localmente ou garantindo a eliminação imediata?
    - **Equidade:** O modelo funciona de forma equitativa entre diferentes tipos de corpo ou posturas, minimizando preconceitos não intencionais?

Exemplos de critérios de sucesso para projetos de plantação:

- "O modelo de reconhecimento de posturas atinge uma precisão global de 85% na classificação de cinco posturas de yoga distintas."
- "Os alunos que utilizam o projeto de feedback do PE demonstram uma melhoria de 10% na execução correta de um exercício específico após utilizarem a ferramenta."
- "A aplicação interativa de narrativa desencadeia com precisão pontos-chave da trama com base em três gestos definidos das personagens."

Ao definir critérios de sucesso claros, mensuráveis e relevantes, orienta eficazmente o desenvolvimento do seu Projeto de Postura da Teachable Machine e assegura que cumpre os seus objetivos pretendidos.

## 5.2 Recolha e preparação de dados: Construir o seu conjunto de dados para poses

Os dados são o motor de qualquer modelo de Aprendizagem Automática. A qualidade, quantidade e diversidade dos seus dados de postura têm um impacto direto no desempenho e na precisão do seu projeto Teachable Machine. Por isso, planear uma estratégia robusta de recolha de dados é essencial para construir um modelo bem-sucedido.

### 5.2.1 Recolha de Dados de Pose: Fontes e Métodos

A qualidade e diversidade do seu conjunto de dados de poses é fundamental para o sucesso do seu projeto de pose na Teachable Machine. Um conjunto de dados bem construído permite que o seu modelo aprenda eficazmente e faça previsões precisas. Esta secção descreve várias fontes e métodos para recolher dados de pose:

- **Captura por webcam:** A Teachable Machine oferece uma funcionalidade útil que permite captar poses diretamente usando a webcam do seu computador. Este método é particularmente útil para recolher poses realizadas por si, alunos ou voluntários diretamente na sala de aula.
    - **Vantagens:**
        - A recolha de dados é fácil e rápida para introdução em tempo real.
        - É possível controlar diretamente a pose, a iluminação e o fundo.
        - É suportada a captura em tempo real de movimentos específicos ou poses estáticas.
    - **Considerações:**
        - Garanta uma iluminação consistente e um fundo claro para uma deteção ótima da pose.
        - A privacidade e o consentimento são cruciais ao gravar pessoas.
        - O sujeito deve ser visível para a webcam, normalmente da cintura ou do corpo inteiro.

💡 Dica do professor:

**A configuração física ideal para o reconhecimento de pose:** Para garantir que o PoseNet deteta com precisão todos os 17 pontos-chave do esqueleto, siga estas regras de configuração:

- **Distância:** O aluno deve manter-se a pelo menos 2 metros (6–7 pés) de distância da webcam, para que a IA possa seguir todo o esqueleto do corpo, da cabeça aos pés.
- **Fundo desobstruído:** Evite estar em frente a estantes cheias de livros ou cartazes; as formas do fundo podem ser confundidas com articulações humanas.
- **Iluminação frontal:** Certifique-se de que a luz incide na frente da pupila. Uma luz de fundo forte transforma a pupila numa silhueta, dificultando a deteção das articulações.

- **Vídeos pré-gravados:** Utilizar vídeos existentes de indivíduos a executar várias poses ou movimentos pode ser um método valioso para recolher dados diversos. É possível extrair fotogramas individuais ou pequenos segmentos desses vídeos.
  - **Vantagens:**
    - O acesso é garantido a uma grande variedade de movimentos que não são facilmente reproduzíveis à demanda.
    - Poupa tempo e esforço comparado com gravar todas as poses sozinho.
    - É fornecido acesso a movimentos especializados (por exemplo, desporto, dança).
  - **Considerações:**
    - Esteja atento às restrições de direitos de autor e aos direitos de utilização de conteúdos de vídeo.
    - A qualidade e consistência do vídeo (por exemplo, resolução, ângulo da câmara) podem variar.
    - Tens de filtrar cuidadosamente e selecionar os segmentos de vídeo relevantes.
- **Aumento de Poses (Conceito Avançado):** Esta técnica envolve aumentar artificialmente o tamanho e a diversidade do seu conjunto de dados de poses aplicando várias transformações a dados de pose existentes. Este pode ser um método valioso para melhorar o desempenho do seu modelo.
  - **Exemplos de técnicas de aumento (frequentemente aplicadas aos dados esqueléticos subjacentes, em vez do vídeo bruto):**

- **Ligeiras rotações:** Pequenas alterações rotacionais nos dados da pose.
- **Escala:** Ajusta o tamanho da pose.
- **Espelhamento:** Inverta a pose horizontalmente (por exemplo, o braço direito torna-se o braço esquerdo).
- **Adição de ruído:** Introdução de ligeiras variações aleatórias nas posições das articulações para simular a variabilidade natural do movimento humano.

- **Vantagens:**
  - Aumenta o tamanho e a diversidade do seu conjunto de dados sem necessidade de recolher novas poses.
  - Pode melhorar a capacidade do seu modelo de generalizar e lidar com variações no movimento humano.
  - Ajuda a evitar o sobreajuste (quando o modelo aprende demasiado bem os dados de treino e tem um desempenho fraco com dados novos).
- **Considerações:**
  - Isto é frequentemente mais complexo para dados de pose do que para imagens ou áudio e muitas vezes requer ferramentas externas para manipular os pontos-chave subjacentes da pose, não apenas o vídeo bruto. Para professores do ensino básico, foque-se em capturas diversas e reais.
  - Aplicar técnicas de aumento de dados de forma sensata; garantir que as transformações permanecem realistas.

Ao recolher dados de posturas, é crucial priorizar considerações éticas, qualidade, diversidade e relevância. Certifique-se de que as suas poses são claramente visíveis, consistentes e representativas dos movimentos que o seu modelo deve reconhecer.

### 5.2.2 Criação de Classes de Pose: Definindo Categorias para o Seu Modelo

No Teachable Machine, as "classes" representam as categorias ou rótulos distintos que o seu modelo de reconhecimento de poses aprende a identificar. Definir estas classes de forma clara e precisa é um passo crucial na preparação do seu conjunto de dados e em garantir que o seu modelo distingue eficazmente entre diferentes posturas ou movimentos. Aqui está um guia para criar classes de posturas:

- **Defina claramente as suas categorias:** Antes de adicionar amostras de pose, dedique algum tempo a definir cuidadosamente as categorias que o seu modelo irá reconhecer. Cada aula deve representar uma postura, gesto ou movimento específico relevante para os objetivos do seu projeto. Certifique-se de que as categorias são bem definidas, inequívocas e mutuamente exclusivas (na medida do possível). Isto significa que deve

haver sobreposição ou confusão mínima entre as categorias. Por exemplo, ao classificar exercícios básicos, as aulas podem ser "em pé", "agachamento" e "avanço".

- **Determine o número de aulas:** O número de aulas que precisa depende da complexidade do seu projeto e do número de posturas ou movimentos distintos a reconhecer. Comece com um número razoável, especialmente se for principiante. Pode sempre adicionar aulas adicionais mais tarde, se necessário. Considere o compromisso entre o número de aulas e os dados de que precisa; mais aulas geralmente exigem mais dados para um treino eficaz de modelos.
- **Dê nomes** apropriados às suas turmas **:** Atribua nomes claros e descritivos às turmas, que reflitam com precisão as posturas ou movimentos que representam. Isto ajuda na organização e garante uma compreensão fácil do objetivo de cada turma. Use convenções de nomenclatura consistentes, por exemplo, verbos de ação claros (por exemplo, "braços levantados", "sentado de pernas cruzadas").
- **Criar classes na Teachable Machine:** A Teachable Machine oferece uma interface intuitiva para criar e gerir classes. Existe uma área disponível para adicionar novas classes, renomear as existentes ou eliminar classes. Siga as instruções no ecrã para criar as suas turmas e atribuir nomes apropriados.
- **Considere as implicações éticas e a privacidade:** Ao trabalhar com dados de pose envolvendo indivíduos, esteja sempre particularmente atento às considerações éticas. Obtenha o consentimento adequado para gravações de vídeo, especialmente dos alunos. Priorize a privacidade garantindo que as gravações são usadas apenas para o seu propósito educativo e não são armazenadas ou partilhadas de forma inadequada. Se possível, utilize poses genéricas que não identifiquem indivíduos.
- **Revise e aperfeiçoe as suas aulas:** Depois de criar o seu conjunto inicial de aulas, reveja-as cuidadosamente para garantir que são adequadas aos objetivos do seu projeto. Considere se precisa de adicionar, remover ou renomear as classes. Muitas vezes, refinar as classes torna-se útil depois de começar a recolha de dados, à medida que ganha uma melhor compreensão das variações de movimento.

Ao definir e criar cuidadosamente as suas aulas de pose, estabelece uma base sólida para o seu projeto de pose no Teachable Machine, garantindo que o seu modelo aprende eficazmente a distinguir entre as categorias especificadas.

### 5.2.3 Aumenta os teus dados de pose: mais exemplos, melhor aprendizagem

A ampliação de dados de poses é uma técnica sofisticada para aumentar artificialmente o tamanho e a diversidade do seu conjunto de dados de postura e movimento corporal. Isto envolve aplicar várias transformações a amostras de pose existentes para criar novas versões,

ligeiramente modificadas. Este método pode melhorar significativamente a robustez e a generalização do seu projeto de pose com a Teachable Machine, ajudando-o a ter um bom desempenho em dados nunca antes vistos, com variações na execução das poses, diferenças individuais ou ângulos de câmara. Aqui está um guia para aumentar dados de poses:

- **Porque usar aumento de pose?**
  - **Aumento do tamanho do conjunto de dados:** Aumentar permite gerar mais dados de treino a partir de poses existentes, expandindo efetivamente o seu conjunto de dados sem necessidade de recolher novas amostras. Isto é particularmente útil quando as gravações das poses originais são limitadas ou difíceis de obter.
  - **Melhor generalização:** Ao introduzir variações nos seus dados de treino, a ampliação ajuda o modelo a aprender características mais robustas e a tornar-se menos sensível a detalhes específicos nas posturas de treino. Isto melhora a capacidade do modelo de generalizar para posturas novas e nunca antes vistas que podem diferir ligeiramente dos dados de treino (por exemplo, uma pose realizada por outra pessoa ou de um ângulo ligeiramente diferente).
  - **Redução do sobreajuste:** O sobreajuste ocorre quando um modelo aprende demasiado bem os dados de treino, incluindo o ruído e as peculiaridades, o que leva a um desempenho fraco em novos dados. O aumento ajuda a prevenir o sobreajuste ao tornar o modelo menos dependente de exemplos específicos de treino e ao encorajá-lo a aprender traços mais generalizáveis para diversas entradas de pose.
- **Técnicas comuns de aumento (frequentemente mais complexas para poses):**
  - **Ligeiras rotações e alterações de escala:** Aplicar pequenas rotações (por exemplo, alguns graus) ou alterações de escala (fazendo a pessoa parecer ligeiramente mais próxima ou mais distante) da pose captada ajuda o modelo a reconhecer a pose, independentemente de pequenas alterações de posição.
  - **Inversão horizontal (espelhamento):** Inverter a pose horizontalmente ajuda o modelo a perceber que uma pose é a mesma independentemente do lado virado para a câmara (por exemplo, um braço esquerdo levantado é igual a um braço direito levantado se espelhado).
  - **Recorte aleatório e tradução:** Ajustar a caixa delimitadora à volta da pessoa ou deslocar ligeiramente a sua posição dentro do enquadramento ajuda o sujeito a focar-se na sua pose, em vez da sua posição exata no enquadramento do vídeo.
  - **Adicionar ruído de fundo:** Embora não seja diretamente um aumento da 'postura', variar o fundo durante a recolha de dados ou adicionar digitalmente alterações subtis ao fundo ajuda o modelo a aprender a ignorar informação visual irrelevante.

- **Aplicar o reforço de dados de postura:**
    - **Funcionalidades incorporadas da Teachable Machine:** A Teachable Machine lida, por natureza, com algumas variações na deteção de poses através do seu modelo subjacente. Para ampliação direta, baseia-se na diversidade de dados de entrada que fornece, abrangendo diferentes ângulos e pessoas.
    - **Ferramentas e bibliotecas externas (para exploração avançada):** Para aumento de poses mais sistemático ou complexo, ferramentas externas podem ser usadas para manipular fotogramas de vídeo ou dados pontuais subjacentes Para os professores do ensino básico, a abordagem mais prática para a ampliação é garantir a **diversidade das amostras** originais recolhidas (alunos diferentes, ligeiras variações na execução, distâncias de câmara diferentes, iluminação variável), em vez de transformações digitais complexas.
- **Melhores Práticas de Aumento:**
    - Aplicar técnicas de aumento de forma sensata. Evite transformar os dados ao ponto de a pose aumentada deixar de representar uma variação realista do original.
    - Tenha em conta os requisitos específicos do seu projeto e escolha técnicas de aumento relevantes para as variações que o seu modelo provavelmente encontrará no uso real.
    - Monitorize o desempenho do seu modelo num conjunto de validação (dados não usados para treino) para garantir que o aumento melhora a generalização e não prejudica o desempenho.

Ao garantir dados diversos e robustos, seja através de captura direta variada ou ampliação avançada, melhora a robustez, precisão e generalização dos seus designs de poses com a Máquina Teachable, conduzindo a modelos de reconhecimento de movimento mais fiáveis e eficazes.

### 5.2.4 Prepare os Seus Dados para a Teachable Machine

Depois de recolher os dados das suas poses e aplicar quaisquer estratégias de aumento desejadas, o passo seguinte é prepará-los para uso na Teachable Machine. A preparação adequada dos dados garante que as amostras de pose estão no formato correto, organizadas de forma eficaz e prontas para treinar o seu modelo de ML. Aqui está um guia para preparar os seus dados:

- **Qualidade da gravação de vídeo:** A Teachable Machine processa fluxos de vídeo para detetar poses. Certifique-se de que as suas gravações de vídeo são claras, bem iluminadas

e mostram claramente o corpo inteiro ou as partes relevantes do corpo. Evite vídeos desfocados ou de baixa resolução.

- **Enquadramento consistente:** Mantenha o enquadramento e a distância da câmara consistentes em todas as amostras de pose dentro de uma única turma. Embora o modelo consiga lidar com alguma variação, a consistência ajuda-os a aprender de forma mais eficaz. O sujeito deve permanecer dentro do enquadramento.
- **Organização dos dados:** Organize as suas amostras de poses em "classes" que correspondam às poses ou movimentos distintos que o seu modelo irá reconhecer. A Teachable Machine retira automaticamente os dados da pose do seu vídeo de entrada. Deve criar uma "classe" separada para cada pose (por exemplo, "De pé", "Sentado", "Braços Levantados").
- **Considerações de fundo:** Embora o modelo de pose Teachable Machine (MoveNet) seja robusto em relação aos fundos, minimizar fundos fragmentados ou desorganizados durante a gravação pode ajudar o modelo a focar-se na pessoa. Um fundo simples e consistente é o ideal.
- **Limpeza de Dados:** Antes de treinar, reveja e limpe o seu conjunto de posturas. Remova quaisquer segmentos de vídeo irrelevantes, inadequados ou corrompidos. Certifique-se de que nenhum objeto indesejado ou pessoa interfere com a pose principal.
- **Divisão de Dados (opcional, mas recomendado):** Para práticas mais avançadas de Aprendizagem Automática, recomenda-se dividir o seu conjunto de dados em três subconjuntos:
    - **Conjunto de treino:** O maior subconjunto, usado para treinar o modelo de ML.
    - **Conjunto de validação:** usado para avaliar o desempenho do modelo durante o treino e ajustar os hiperparâmetros.
    - **Conjunto de Teste:** usado para avaliar o desempenho do modelo final após a conclusão do treino. O Teachable Machine não requer divisão explícita para uso básico, mas é uma boa prática para avaliação rigorosa do modelo. Obtém-se um efeito semelhante ao reservar uma parte dos seus dados e não a usar durante a fase inicial de treino. Se optar pela divisão de dados, certifique-se de que a distribuição das classes é semelhante em todos os subconjuntos.
- **Carregar dados para a Teachable Machine:** Assim que os seus dados estiverem preparados, estão prontos para serem carregados na Teachable Machine. A plataforma fornece ferramentas intuitivas para carregar dados de pose, normalmente permitindo-lhe:
    - Grava amostras de poses diretamente usando a tua webcam.
    - Carregue ficheiros de vídeo do seu computador. Siga as instruções no ecrã para carregar os seus dados e associá-los às aulas corretas.

Ao preparar cuidadosamente os seus dados de pose, garante que estão nas condições ideais para treinar o seu projeto de pose na Teachable Machine, levando a um melhor desempenho do modelo e resultados mais fiáveis.

💡 Dica do professor

**Gerir espaços pequenos:** Se o espaço da sua sala de aula for demasiado limitado para rastreios completos, use estas alternativas práticas:

- **Posturas da parte superior do corpo/sentado:** Treine o seu modelo usando gestos da parte superior do corpo (braços, ombros, inclinação da cabeça) enquanto os alunos permanecem sentados nas suas secretárias.
- **A opção de corredor ou ginásio:** Permitir que grupos de alunos utilizem corredores abertos, o recreio da escola ou o ginásio durante a fase de recolha de dados de 10 minutos.
- **Conjuntos de vídeo pré-gravados:** Permitem aos alunos importar clipes de vídeo pré-gravados de rotinas de movimento em vez de capturar transmissões ao vivo da webcam.

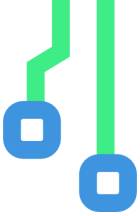
## 5.3 Treino e Avaliação de Modelos: Dar Vida à Sua IA de Poses

### 5.3.1 Treinar o seu modelo de pose: passo a passo

Depois de preparar o seu conjunto de dados de poses, o passo seguinte envolve treinar o seu modelo de Aprendizagem Automática no Teachable Machine. Este processo de treino consiste em inserir os dados da sua posição no modelo, permitindo-lhe aprender e reconhecer os padrões e características que distinguem as diferentes classes de posturas que definiu. O Teachable Machine simplifica este processo, tornando-o acessível mesmo para quem não tem experiência em programação. Aqui está um guia passo a passo para treinar o seu modelo de pose:

- **Vai ao teu projeto:** Teachable Machine aberta e vai ao Projeto de Postura em que tens trabalhado. Certifica-te de que os teus dados de postura estão carregados e organizados nas turmas corretas.
- **Analise os seus dados:** Antes de iniciar o processo de treino, reserve um momento para analisar os seus dados. Confirme a sua precisão e certifique-se de que cada aula contém um número suficiente de amostras representativas de poses. Normalmente, pode analisar as amostras de pose em cada aula diretamente na interface do Teachable Machine. Preste atenção às variações na execução ou aos elementos de fundo.

- **Iniciar treino:** A Teachable Machine fornece um botão ou comando claro para iniciar o processo de treino. Este é um botão claramente visível, normalmente intitulado "Model Train". Clique neste botão para iniciar o treino.
- **Processo de treino:** Assim que o treino começa, a Teachable Machine começa a processar os dados das suas poses. A plataforma utiliza algoritmos de Aprendizagem Automática para analisar os pontos-chave das poses detetadas no vídeo e identificar características que distinguem as diferentes classes. Durante o treino, o modelo ajusta os seus parâmetros internos para otimizar a sua capacidade de classificar corretamente as poses. A Teachable Machine fornece feedback visual sobre o progresso do treino. Isto inclui barras de progresso, mensagens ou animações que indicam que o treino está em curso. A duração do processo de treino depende do tamanho e complexidade do seu conjunto de dados, bem como do poder de processamento do seu computador ou dos servidores da plataforma.
    - **Como a Pose AI vê o corpo (A sobreposição das articulações):** Ao contrário dos Projetos de Imagem (que analisam píxeis, roupas e cores), os Projetos de Pose usam um modelo (MoveNet/PoseNet) que ignora as aparências visuais e mapeia 17 articulações humanas-chave (cotovelos, ombros, ancas, joelhos). Dica: Roupa larga ou demasiado larga pode obscurecer ângulos articulares; incentive os alunos a usarem roupa justa ou a ajustarem as suas posições para que as articulações principais permaneçam claramente visíveis.
- **Não é necessária programação:** Uma vantagem fundamental do Teachable Machine é a forma como gere cálculos complexos de treino de modelos em segundo plano. Não precisa de escrever código nem de ter conhecimentos especializados de algoritmos de Machine Learning para treinar o seu modelo.
- **Definições Avançadas de Treino (opcionais para exploração adicional):** Embora tenha sido concebida para ser simples, a Teachable Machine oferece "Definições Avançadas" que permitem aos utilizadores afinar o processo de treino. Estas definições podem influenciar a forma como o modelo aprende e o seu desempenho final. A disponibilidade e a natureza específica destas definições podem variar ligeiramente com as atualizações da plataforma Teachable Machine.
    - **Estações:** Uma representa uma passagem completa por todo o conjunto de dados de treino durante o processo de treino. Aumentar o número de estações geralmente permite uma aprendizagem mais aprofundada, mas também aumenta o risco de sobreajuste (onde o modelo tem bom desempenho em dados de treino mas tem um desempenho fraco em dados novos). O Teachable Machine permite o ajuste das estações, dando-lhe controlo sobre a duração do treino.



💡 Dica de treino de poses:

Como rastrear 17 articulações em quadros móveis é complexo, os modelos de pose frequentemente exigem mais rondas de treino. Se o seu modelo hesitar ou oscilar entre classes, tente aumentar as Estações de 50 para 100 em Configurações Avançadas para dar mais tempo ao modelo para mapear as relações entre as articulações.

- **Tamanho do lote:** Isto refere-se ao número de amostras de dados (frames de pose, neste caso) que o modelo processa de cada vez durante cada atualização de parâmetro. Ajustar o tamanho do lote afeta a velocidade de treino e a dinâmica de aprendizagem. O Teachable Machine oferece opções para diferentes tamanhos de lote.
- **Taxa de aprendizagem:** Um parâmetro crucial, a taxa de aprendizagem controla o tamanho do passo que o modelo realiza para atualizar os seus parâmetros com base no erro calculado (perda). Uma taxa de aprendizagem demasiado alta causa divergência e falha na aprendizagem, enquanto uma taxa demasiado baixa atrasa significativamente o processo de treino. Enquanto a Teachable Machine simplifica muitos aspetos, fluxos de trabalho avançados de aprendizagem automática envolvem esta taxa. Se estiver disponível como opção, avance com cautela.
- **Outros hiperparâmetros:** Os modelos de aprendizagem automática têm parâmetros chamados hiperparâmetros que controlam o processo de aprendizagem. A Teachable Machine disponibiliza alguns destes parâmetros para ajuste. A afinação destes frequentemente requer experimentação e compreensão dos princípios da aprendizagem automática.
- **Utilização de definições avançadas:** Se optar por usar definições avançadas, recomenda-se geralmente uma abordagem sistemática. Mude uma definição de cada vez, observe o seu impacto no desempenho do modelo e acompanhe meticulosamente os experimentos e resultados. A utilização eficaz requer frequentemente uma compreensão mais profunda dos conceitos de aprendizagem automática. Para quem é novo na aprendizagem automática, é aconselhável começar pelas definições pré-definidas e explorar gradualmente as opções avançadas à medida que ganha experiência.

- **Dicas de treino:**

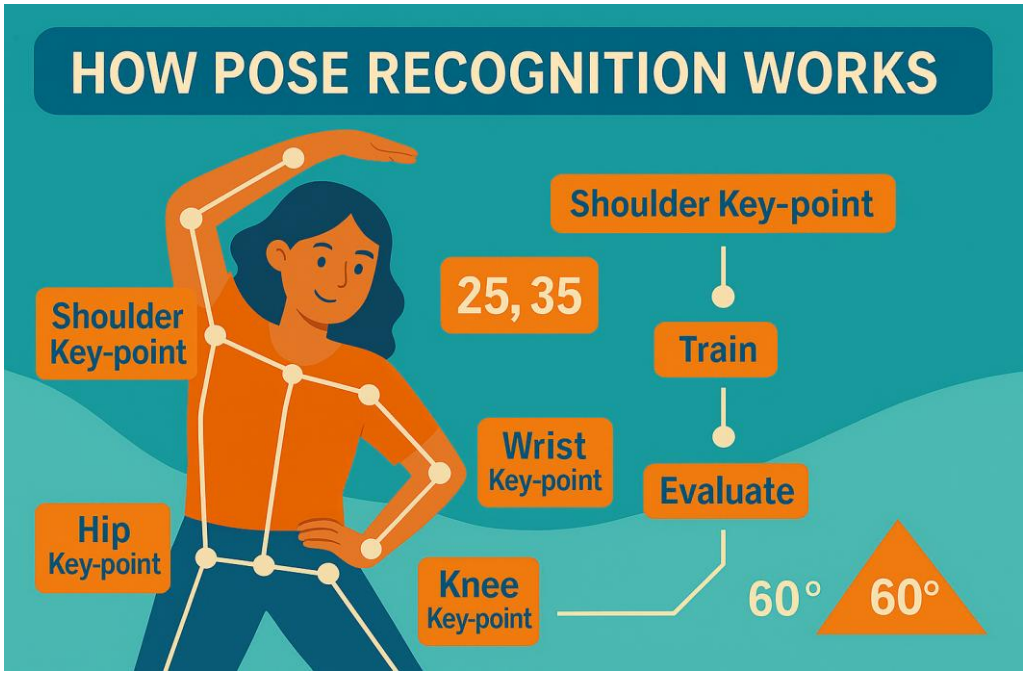
- **Comece com dados suficientes:** Certifique-se de que existem dados adequados em cada aula antes do treino. Um conjunto de dados equilibrado, com um número razoável de amostras de pose por turma, geralmente produz melhores resultados.
- **Acompanhar o progresso (se disponível):** Se a Teachable Machine fornecer feedback sobre o progresso dos treinos, acompanhe-o para perceber como o modelo aprende.
- **Treino iterativo:** Pode ser necessário treinar o modelo várias vezes, especialmente se os resultados iniciais forem insatisfatórios. Ajuste o seu conjunto de dados, adicione mais dados ou modifique classes e depois retreine o modelo.

- **Formação Concluída:** Assim que o processo de treino está concluído, a Teachable Machine notifica-o. O seu modelo de reconhecimento de poses está agora treinado e pronto para avaliação e utilização.

O Teachable Machine simplifica o processo de treino, tornando-o acessível a uma vasta gama de utilizadores. Ao seguir estes passos e garantir um conjunto de dados bem preparado, treina eficazmente o seu modelo de reconhecimento de posturas e começa a explorar as suas capacidades.

**Como Funciona o Reconhecimento de Posturas (Simplificado):**

O modelo de pose da Teachable Machine utiliza um algoritmo baseado em pontos-chave — coordenadas específicas do corpo humano (como as articulações). Captura posições e ângulos relativos, transformando-os em números para treino e previsão.



| 🧠 Processo simplificado | | | |
|---|---|---|---|
|  |  |  |  |
| 1. A webcam capta a postura corporal | 2. São detetados pontos-chave | 3. Os padrões são analisados | 4. O modelo aprende a classificar movimentos |

O reconhecimento de poses demonstra como a IA pode interpretar o movimento, mas também destaca os seus limites — o ângulo da câmara, a iluminação e a velocidade de movimento podem afetar a precisão.

### 5.3.2 Avaliação de Desempenho do Modelo: Compreender a Precisão e as Métricas

Depois de treinar o seu modelo de pose na Teachable Machine, avaliar o seu desempenho é crucial para determinar se funciona bem e se cumpre os critérios de sucesso do seu projeto. A avaliação envolve testar o modelo com dados de pose que não viu durante o treino e analisar as suas previsões. Aqui está um guia para avaliar o desempenho do modelo em projetos de pose:

- **Pré-visualização do Teachable Machine:** Uma funcionalidade de pré-visualização integrada no Teachable Machine permite-lhe testar rapidamente o seu modelo treinado. Pode usar a sua webcam para fornecer novos dados de pose ou carregar vídeos existentes, e depois observar como o modelo os classifica. Esta pré-visualização oferece uma forma intuitiva de avaliar rapidamente o desempenho do seu modelo. Observe se o modelo identifica corretamente posturas ou movimentos nos dados fornecidos. Preste atenção a quaisquer classificações erradas ou situações em que o modelo pareça incerto.
- **Compreenda a precisão:** A precisão é uma métrica comum para avaliar modelos de classificação. Representa a proporção global de previsões corretas feitas pelo modelo. Por exemplo, se fornecer ao modelo 100 amostras de pose de teste e o modelo obtiver corretamente 85, a precisão é de 85%. Embora a precisão seja uma métrica útil, é importante estar consciente das suas limitações, especialmente com conjuntos de dados desequilibrados (onde algumas classes têm significativamente mais dados do que outras).
- **Matriz de confusão:** Uma matriz de confusão fornece uma análise mais detalhada do desempenho do seu modelo. Esta tabela mostra o número de previsões corretas e

incorretas para cada classe. As linhas normalmente representam as classes reais, enquanto as colunas representam as classes previstas. Analisar a matriz de confusão ajuda a identificar que classes o modelo tem dificuldade em distinguir e onde comete mais erros.

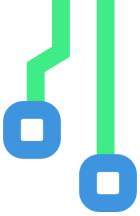
- **Precisão e recordação (simplificada):** Outras métricas importantes, precisão e recordação, dão-lhe uma compreensão mais aprofundada do desempenho do seu modelo, especialmente com conjuntos de dados desequilibrados.
    - **Precisão:** mede a proporção de identificações positivas que estavam realmente corretas. Responde à pergunta: "De todas as vezes em que o modelo indicou que era uma determinada classe, com que frequência acertou?"
    - **Recordação:** Mede a proporção de casos positivos reais que foram corretamente identificados pelo modelo. Responde à seguinte pergunta: "De todas as vezes em que foi *realmente* uma determinada classe, com que frequência o modelo a indicou?" Uma pontuação de precisão elevada indica que o modelo se destaca na prevenção de falsos positivos, enquanto uma pontuação elevada na recordação significa que é eficaz na identificação de todos os casos de uma determinada classe.
- **Pontuação F1 (simplificada):** A pontuação F1 combina precisão e recordação num único valor. Fornece uma medida equilibrada do desempenho de um modelo, especialmente quando existe um desequilíbrio entre classes. Geralmente, uma pontuação F1 mais alta indica melhor desempenho.
- **Melhores práticas de avaliação:**
    - **Use um conjunto de testes separado:** Para uma avaliação imparcial, é crucial testar o seu modelo com dados que não encontrou durante o treino. Isto é conhecido como conjunto de testes.
    - **Avalie com base em dados representativos:** Certifique-se de que os seus dados de teste representam com precisão as poses reais que o seu modelo irá encontrar. Isto significa incluir variações na persona, vestuário, iluminação e fundo.
    - **Considere os objetivos do seu projeto:** As métricas mais importantes para avaliar o seu modelo dependem dos objetivos específicos do seu projeto. Se evitar falsos positivos for fundamental (por exemplo, um sistema que o alerte para uma postura incorreta), priorize a precisão. Se identificar todas as instâncias de uma aula for crucial (por exemplo, registar todas as ocorrências de um passo de dança específico), priorize a recuperação.
    - **Avaliação iterativa:** A avaliação é um processo iterativo. Pode ser necessário avaliar o seu modelo várias vezes, ajustar o seu conjunto de dados ou processo de treino, e depois reavaliar para ver se as alterações melhoraram o desempenho.

Ao avaliar cuidadosamente o desempenho do seu modelo usando métricas e boas práticas adequadas, ganha uma compreensão clara dos seus pontos fortes e fracos e toma decisões informadas sobre como o melhorar.

### 5.3.3 Resolução de problemas e melhoria do seu modelo

É comum encontrar desafios e áreas de melhoria durante o treino e avaliação do seu projeto de Teachable Machine. O seu modelo pode não funcionar inicialmente como esperado, ou pode notar fraquezas específicas nas suas previsões. A resolução de problemas e a melhoria iterativa do seu modelo são partes essenciais do processo de aprendizagem automática. Aqui está um guia para o ajudar:

- **Identifique os problemas comuns:**
  - **Baixa precisão:** O modelo faz um grande número de previsões incorretas.
  - **Overfit:** O modelo tem bom desempenho em dados de treino, mas tem um desempenho fraco em dados novos e nunca antes vistos. Isto indica que o modelo aprendeu demasiado bem os dados de treino, incluindo ruído e as suas peculiaridades.
  - **Confusão entre classes:** O modelo tem dificuldade em distinguir entre certas classes, frequentemente classificando erradamente uma pose como outra. Isto é comum quando as poses são muito semelhantes ou as transições entre elas são pouco claras.
  - **Preconceito:** O modelo tem um desempenho significativamente melhor em alguns grupos ou tipos de corpo do que noutros, o que indica potencial viés nos dados ou modelos.
- **Estratégias para resolução de problemas e melhoria:**
  - **Aumentar a quantidade de dados:** Se o seu modelo apresentar baixa precisão, aumentar a quantidade de dados de treino é uma solução comum. Recolha mais amostras de pose para cada turma, garantindo um conjunto de dados equilibrado. Um conjunto de dados maior fornece ao modelo mais informação para aprender, melhorando a sua capacidade de generalização.
  - **Melhorar a qualidade e diversidade dos dados:** Analise os dados existentes para identificar amostras de poses de baixa qualidade ou não representativas. Remova gravações que estejam desfocadas, mal iluminadas ou que não mostrem claramente a pose pretendida. Aumente a diversidade do seu conjunto de dados capturando poses de diferentes indivíduos, em várias condições de iluminação e de ângulos ligeiramente diferentes. Considere adicionar exemplos onde a pose está



parcialmente obscurecida ou é realizada com ligeiras variações, se for relevante para a sua aplicação.

- **Aperfeiçoe as suas classes:** Se o seu modelo confundir certas classes, reveja as definições de classes para garantir clareza e distinção. Se necessário, junte classes muito semelhantes ou crie subclasses mais específicas para reduzir ambiguidades. Certifique-se de que as amostras de pose dentro de cada classe são representativas e não se sobrepõem significativamente a outras classes.
- **Abordar o overfit:** Quando o seu modelo está a experienciar overfit, considere estas abordagens:
  - **Aumento de dados (conforme discutido em 5.2.3):** O aumento, ao introduzir variações sintéticas, ajuda a evitar o sobreajuste.
  - **Simplificar o modelo (se aplicável):** Embora a Teachable Machine abstraia grande parte da arquitetura do modelo, em ML mais avançado, simplificar o modelo pode, por vezes, ajudar a resolver o overfitting.
  - **Paragem precoce (se disponível):** Alguns sistemas de treino incorporam 'paragem antecipada', onde o treino é interrompido quando o desempenho num conjunto de validação começa a deteriorar-se.
- **Verifique se há viés:** Analise cuidadosamente o seu conjunto de dados para identificar potenciais fontes de viés. Certifique-se de que os seus dados representam a diversidade de indivíduos e posturas que o seu modelo pretende processar. Se for identificado algum viés (por exemplo, baixo desempenho para certos tipos de corpo ou tons de pele), recolha dados mais diversos para equilibrar o seu conjunto de dados e mitigar o viés. Avalie o desempenho do seu modelo em diferentes grupos para identificar e corrigir quaisquer disparidades.
- **Treino e avaliação iterativos:** A resolução e melhoria de problemas são processos iterativos. Faça pequenas alterações ao seu conjunto de dados, processo de treino ou definições de classes, depois reforme e reavalie o seu modelo. Acompanhe meticulosamente as alterações feitas e o seu impacto no desempenho. Use métricas de avaliação (precisão, exatidão, recordação, matriz de confusão) para orientar as suas melhorias.
- **Procure ajuda e recursos:** Se estiver a ter dificuldades em melhorar o desempenho do seu modelo, não hesite em procurar ajuda e recursos. Fóruns online, tutoriais e comunidades oferecem informações e orientações valiosas. A documentação e os recursos de suporte da Teachable Machine também fornecem dicas e conselhos úteis para resolução de problemas.

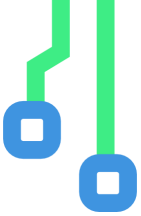
Ao resolver problemas sistematicamente e melhorar iterativamente o seu modelo, supera desafios, melhora o seu desempenho e alcança os resultados desejados nos seus projetos de pose Teachable Machine.

## 5.4 Aplicações na sala de aula: colocar a IA em ação

### 5.4.1 Atividades de aprendizagem interativas com reconhecimento de poses

A tecnologia de reconhecimento de posturas, desenvolvida pela Teachable Machine, serve como uma ferramenta valiosa para criar atividades de aprendizagem envolventes e interativas que envolvem movimento físico na sala de aula. Incorporar IA baseada em poses nas suas aulas proporciona aos alunos experiências práticas, melhora a sua compreensão da mecânica corporal e promove um ambiente de aprendizagem mais dinâmico. Aqui estão alguns exemplos de atividades de aprendizagem interativas com reconhecimento de posturas:

- **Guias de fitness e exercício: Desenhe** uma atividade onde os alunos utilizem um modelo de Teachable Machine para verificar a postura enquanto realizam vários exercícios. Os alunos podem receber feedback imediato sobre se a sua postura é um exemplo "correto", promovendo a técnica correta e prevenindo lesões. Isto é particularmente útil em aulas de Educação Física ou em rotinas de alongamentos guiadas.
- **Prática de Dança e Representação:** Desenvolva uma ferramenta interativa onde os alunos pratiquem passos de dança ou poses teatrais. Um modelo da Teachable Machine pode ser treinado para reconhecer coreografias específicas ou posturas de personagem, fornecendo feedback sobre a precisão. Isto permite que os alunos aperfeiçoem a sua interpretação de papéis de forma independente, tornando a prática artística mais dinâmica.
- **Narrativa interativa e role-playing:** O reconhecimento de poses pode estimular a criatividade e as atividades de narrativa. Os alunos podem usar um modelo de Teachable Machine para desencadear diferentes caminhos narrativos ou ações das personagens com base nos seus gestos físicos ou poses dramáticas. Isto estimula a imaginação, a expressão física e as competências de contar histórias dos aprendentes, dando vida às histórias através do movimento. Por exemplo, adotar uma 'pose do herói' pode levar a história para um momento de triunfo.
- **Acessibilidade e ferramentas de comunicação:** Explore a criação de ferramentas básicas de comunicação baseadas em poses para alunos com necessidades específicas. Um modelo de Teachable Machine pode ser treinado para reconhecer gestos simples (por exemplo, "sim", "não", "mais") que, por sua vez, desencadeiam respostas ou ações correspondentes num ecrã. Isto promove uma comunicação inclusiva e oferece métodos alternativos de interação.



- **Discussão sobre IA inclusiva:** Enriqueca esta atividade treinando modelos de poses com utilizadores a realizar gestos sentados ou numa cadeira de rodas. Pergunte aos seus alunos: "Se uma aplicação de exercícios com IA é treinada apenas com adultos em pé, quão acessível é para pessoas com diferenças de mobilidade?" Isto liga diretamente os designs físicos ao design tecnológico inclusivo.

- **Interfaces Orientadas por Gestos:** Envolver os alunos no design de interfaces simples controladas por gestos para jogos ou aplicações educativas. Os alunos podem treinar um modelo da Máquina Ensinable para reconhecer movimentos manuais específicos (por exemplo, acenar para a esquerda/direita, apontar para cima/baixo) para controlar uma personagem no ecrã ou navegar numa apresentação. Isto introduz conceitos de interação e design humano-computador.
- **Análise de arte e escultura:** Os alunos podem usar o reconhecimento de poses para analisar posturas em obras de arte ou esculturas famosas, treinando um modelo para identificar poses comuns ou convenções artísticas históricas. Isto associa a tecnologia à história da arte e à análise visual.

Estas atividades de aprendizagem interativas demonstram o potencial do reconhecimento de posturas para transformar a experiência em sala de aula, tornando-a mais envolvente, interativa e eficaz, especialmente para alunos com aprendizagem cinestésica.

### 5.4.2 Integração da IA posing em disciplinas específicas

As capacidades de reconhecimento de poses da Teachable Machine integram-se perfeitamente numa vasta gama de aulas específicas de cada disciplina, enriquecendo o currículo e proporcionando aos alunos experiências de aprendizagem únicas. Ao adaptar designs de IA de pose a disciplinas específicas, os educadores aumentam o envolvimento dos alunos, promovem uma compreensão mais profunda e promovem a aprendizagem interdisciplinar. Aqui estão alguns exemplos de como integrar a IA de poses em diferentes disciplinas do ensino básico:

- **Educação física e saúde:**
  - **Análise da forma do exercício:** Podem ser criados desenhos que classifiquem diferentes exercícios físicos, como agachamentos, avanços ou polichinelos, com base na forma correta ou incorreta. Os alunos treinam um modelo para reconhecer movimentos precisos, recebendo feedback imediato sobre a sua técnica. Isto contribui para o desenvolvimento físico adequado e para a prevenção de lesões.
  - **Guias de yoga e alongamentos:** Desenvolva projetos que reconheçam posturas específicas de yoga ou rotinas de alongamento. Os alunos podem usar um modelo

para verificar se estão a manter uma postura corretamente, melhorando a sua compreensão do alinhamento e flexibilidade do corpo.

- **Artes performativas (dança, teatro, mímica):**
  - **Prática de coreografia:** Podem ser desenvolvidos projetos que classifiquem e verifiquem passos ou sequências de dança específicas. Os alunos treinam um modelo para reconhecer passos, recebendo feedback sobre a sua execução. Isto ajuda na prática autónoma e na precisão da execução.
  - **Expressão dramática:** Crie projetos que classifiquem diferentes poses emocionais ou de carácter relacionadas com a narrativa ou teatro. Os alunos treinam um modelo para reconhecer uma 'pose feliz', uma 'pose triste' ou a postura de uma personagem específica numa peça. Isto melhora a compreensão da comunicação não verbal e da presença em palco.
  - **Estudos de mímica e gestos:** Os alunos podem explorar o mímico treinando modelos para reconhecer gestos ou ações icónicas, compreendendo como a linguagem corporal específica transmite significado.
- **Estudos Sociais e Culturais:**
  - **Formas de dança cultural:** Podem ser criados projetos que classifiquem poses ou passos básicos de diferentes danças culturais. Os alunos aprendem sobre culturas globais através do movimento, treinando modelos para reconhecer elementos específicos da dança cultural.
  - **Gestos históricos:** Explore projetos que classifiquem gestos ou poses históricas (por exemplo, cumprimentos, reverências respeitosas de diferentes épocas). Os alunos adquirem compreensão das normas sociais históricas e da comunicação.
- **Explorações interdisciplinares (ligação para STEM e outras disciplinas):**
  - **Interação Humano-Computador (Introdutória):** Os alunos podem desenhar interfaces simples controladas por gestos para jogos educativos ou apresentações. Isto envolve treinar um modelo para reconhecer movimentos das mãos (por exemplo, acenar para a esquerda/direita, apontar para cima/baixo) para controlar elementos no ecrã, introduzindo conceitos fundamentais de design de interação.
  - **Biomecânica (simplificada):** Explore conceitos biomecânicos básicos, classificando posturas eficientes e ineficientes para atividades como levantar ou empurrar. Isto ajuda os alunos a compreender a física do movimento.
  - **Contar histórias com movimento:** Integre o reconhecimento de poses em atividades interativas de narração. Os alunos utilizam um modelo de Teachable Machine para desencadear diferentes caminhos narrativos ou ações das personagens com base nos seus gestos físicos ou poses dramáticas. Isto estimula

a imaginação, a expressão física e as competências de contar histórias, dando vida às histórias através do movimento.

Estes exemplos ilustram a versatilidade de posar IA na educação, demonstrando a sua adaptabilidade para melhorar a aprendizagem em múltiplas disciplinas. A integração de projetos de pose Teachable Machine em aulas específicas permite aos educadores criar experiências de aprendizagem envolventes, interativas e eficazes para os seus alunos, com especial foco no movimento e na expressão física

**Tabela resumida: Projetos específicos de reconhecimento de poses por disciplina**

| Disciplina | Ideia de Projeto de Sala de Aula | Objetivo de Aprendizagem |
|---|---|---|
| Educação física e saúde | Analise a técnica em agachamentos, avanços, polichinelos ou alongamentos de yoga. | Promova a técnica correta de movimento, o alinhamento postural e a prevenção de lesões. |
| Artes performativas | Verifique os passos de uma coreografia de dança ou distinga poses de linguagem corporal que transmitam emoções. | Melhorar a precisão da interpretação e explorar a expressão emocional não verbal |
| Estudos sociais e culturais | Classifique posturas tradicionais de dança cultural ou reverências/cumprimentos históricos respeitosos. | Estabelecer ligações entre o movimento físico, a história cultural e as normas sociais não verbais. |
| Explorações interdisciplinares (ligação às STEM e outras disciplinas) | Desenhe comandos de gestos (aceno esquerda/direita) para controlar personagens de jogos no Scratch. | Compreenda a interação humano-computador, sinais de sensores e biomecânica básica. |

### 5.4.3 Estratégias de avaliação usando designs de IA baseados em pose

Projetos de IA baseados em pose, criados com a Teachable Machine, servem como ferramentas valiosas para várias estratégias de avaliação destinadas a avaliar a aprendizagem dos alunos,

fornecer feedback e acompanhar o progresso, especialmente em áreas que envolvem demonstração física, mecânica corporal ou comunicação não verbal. Estes projetos oferecem oportunidades únicas para avaliação autêntica, permitindo aos alunos demonstrar compreensão e competências de forma prática e envolvente. Aqui estão alguns exemplos de estratégias de avaliação que utilizam projetos de IA baseados em pose:

- **Avaliação baseada no desempenho (competências físicas):** A utilização de projetos de IA baseados em posturas permite-lhe avaliar a capacidade dos alunos de aplicar conhecimentos e competências em situações físicas práticas. Apresente aos alunos exercícios, rotinas de dança ou movimentos que exijam o uso dos seus modelos para autocorreção ou demonstração. Avalie o seu desempenho com base na precisão e eficácia das previsões do modelo, bem como na sua capacidade de interpretar e usar os resultados. Por exemplo, os alunos podem usar um modelo para verificar as suas posturas de yoga ou demonstrar a forma correta de um movimento ginástico.
- **Avaliação baseada em projetos:** Atribuir projetos de IA baseados em poses como principal tarefa de avaliação exige que os alunos desenhem, desenvolvam e avaliem os seus próprios modelos de reconhecimento de posturas. Avalie a compreensão dos alunos sobre os conceitos e competências envolvidos, como recolha de dados (gravação de poses), treino de modelos, avaliação e aplicação. Avalie a qualidade dos seus projetos, incluindo a precisão do modelo, funcionalidade e criatividade. Proporcione oportunidades para os alunos apresentarem os seus projetos, explicando as suas escolhas de design e as conclusões a que chegaram. A avaliação baseada em projetos permite uma avaliação holística da aprendizagem dos alunos e proporciona-lhes um sentido de propriedade do seu trabalho.
- **Avaliação formativa:** Projetos de IA baseados em posturas podem ser integrados em atividades de avaliação formativa para monitorizar a aprendizagem dos alunos e fornecer feedback contínuo. Use modelos do Teachable Machine para criar exercícios ou atividades interativas que permitam aos alunos verificar a sua compreensão de conceitos físicos ou praticar movimentos específicos. Forneça aos alunos feedback imediato sobre o seu desempenho, identificando áreas que necessitam de apoio adicional. A avaliação formativa de posturas por IA ajuda os alunos a acompanhar o progresso e a identificar áreas de melhoria nas competências físicas.
- **Autoavaliação e avaliação entre pares:** Incentive os aprendentes a utilizarem designs de IA baseados em poses para autoavaliação e avaliação entre pares. Isto promove metacognição, pensamento crítico e competências de colaboração. Os alunos utilizam os seus modelos para avaliar o seu próprio desempenho físico ou para dar feedback aos

colegas sobre o design das suas posturas. Fornecer aos alunos critérios e orientações claros para autoavaliação e avaliação entre pares, com foco no feedback construtivo.

- **Avaliação do portefólio:** Inclua projetos de IA baseados em poses nos portfólios dos alunos para mostrar a sua aprendizagem e conquistas ao longo do tempo. Os portefólios oferecem uma visão abrangente do crescimento e desenvolvimento dos alunos, destacando pontos fortes, competências e progresso nas áreas físicas e relacionadas com IA. Os alunos escolhem os seus melhores projetos para inclusão e refletem sobre as suas experiências de aprendizagem.

Exemplos de tarefas de avaliação para projetos de pose:

- "Desenha um modelo de reconhecimento de poses que classifique três alongamentos diferentes e usa-o para guiar os teus colegas numa rotina de aquecimento."
- "Desenvolver um jogo baseado em poses em que os alunos executem corretamente as poses para avançar de nível, demonstrando compreensão dos movimentos físicos."
- "Criar uma avaliação baseada na performance onde os alunos utilizam um modelo de reconhecimento de poses para demonstrar a técnica correta de um passo específico de dança de uma dança cultural."
- "Use um modelo de Teachable Machine para criar uma atividade interativa que ajude os alunos a distinguir entre linguagem corporal 'ativa' e 'relaxada' em cenários de comunicação."

Ao incorporar projetos de IA baseados em poses numa variedade de estratégias de avaliação, os educadores criam formas autênticas, envolventes e eficazes de avaliar a aprendizagem dos alunos e fomentar uma compreensão mais profunda em áreas relacionadas com movimento, expressão física e aprendizagem cinestésica.

# Módulo 6: Estratégias de integração na sala de aula: abordagens pedagógicas

Integrar novas tecnologias, como a IA, na sala de aula requer abordagens pedagógicas bem pensadas. Este módulo foca-se em estratégias práticas para incorporar eficazmente a Teachable Machine nas suas práticas de ensino, garantindo alinhamento com os objetivos curriculares, promovendo a aprendizagem centrada no aluno e abordando considerações éticas. Também abordamos desafios comuns relatados pelos educadores e oferecemos soluções para apoiar a integração bem-sucedida da IA.

## 6.1 Integre a Teachable Machine no seu planeamento de aulas

Conceber experiências de aprendizagem eficazes com a Teachable Machine envolve analisar cuidadosamente como esta ferramenta se alinha com os objetivos curriculares e melhora as práticas pedagógicas existentes. Oferece uma oportunidade única para transformar as aulas tradicionais em explorações dinâmicas e interativas.

- **Alinhar os projetos Teachable Machine com os objetivos curriculares:** A integração bem-sucedida começa por garantir que os projetos Teachable Machine apoiam diretamente os seus objetivos de aprendizagem específicos da disciplina. Considere como o uso do reconhecimento de imagem, áudio ou poses pode ajudar os alunos a compreender conceitos de ciência ou linguagem e literatura de forma mais concreta. Por

exemplo, classificar sons de animais (projeto áudio) ou identificar diferentes tipos de folhas (projeto de imagem) apoia diretamente as aulas de biologia. Construir um modelo para reconhecer palavras corretamente pronunciadas (projeto áudio) reforça diretamente a aquisição da linguagem. Ao ligar claramente os projetos aos resultados de aprendizagem, os alunos interagem intencionalmente com a tecnologia.

- **Desenvolver atividades envolventes e interativas:** A Teachable Machine promove a aprendizagem ativa e prática por natureza. Envolva os alunos na criação dos seus próprios modelos de ML, permitindo-lhes participar na recolha de dados, formação e avaliação. Esta abordagem experiencial promove uma compreensão e envolvimento mais profundos em comparação com métodos de aprendizagem passiva. Atividades em que os alunos desenham modelos para resolver um problema simples na sala de aula, ou criam questionários interativos usando os seus próprios dados, aumentam significativamente a motivação.
- **Incorpore o Teachable Machine nos planos de aula:** Integrar o Teachable Machine nos planos de aula existentes deve ser fluido. Pode servir como atividade introdutória a um novo tema, como ferramenta para reforçar conceitos ou como método de aprendizagem baseado em projetos. Por exemplo, uma aula de ciência dos ecossistemas pode começar com os alunos a treinarem um modelo áudio para identificar diferentes chamados de animais de um habitat específico. Uma aula de linguagem e literatura verbal pode envolver um projeto de pose, no qual os alunos demonstram e avaliam verbos de ação. Ao simplificar a criação de materiais e exercícios, o Teachable Machine também pode ajudar a reduzir a carga de trabalho dos professores, libertando tempo para um ensino mais focado e interação com os alunos.

📝 Guia do Professor:

**A estrutura da lição rápida de 60 minutos:** Para manter a sua aula dentro do horário e evitar que a recolha de dados ocupe todo o período letivo, siga este ritmo com intervalos de tempo definidos:

- **0–10 min (Introdução e Ética):** Introduza a questão central, explique o que a IA irá aprender e estabeleça regras de consentimento e privacidade relativamente aos dados.
- **10–25 min (recolha de dados):** Os alunos trabalham em grupos para recolher ou carregar amostras (estritamente limitado a 15 minutos).
- **25–35 min (Treino):** Realize o treino do modelo e observe a barra de progresso.
- **35–50 min (Testes e iterações):** Teste o modelo com novos dados de entrada, identifique erros de previsão e aperfeiçoe o conjunto de dados.
- **50–60 min (Análise e reflexão):** Discutir limitações do modelo, viés do conjunto de dados e lições práticas a aprender.

## 6.2 Promoção da aprendizagem centrada no aluno com IA

A Teachable Machine é uma ferramenta poderosa para mudar a dinâmica da sala de aula para uma abordagem centrada no aluno. Capacita os alunos a tornarem-se participantes ativos na sua jornada de aprendizagem, promovendo a investigação, a criatividade e o pensamento crítico.

- **Promover a aprendizagem baseada na investigação:** A Teachable Machine incentiva os alunos a fazer perguntas e a investigar fenómenos através da experimentação. Os alunos podem formular hipóteses sobre como uma máquina "aprende", recolher dados para testar as suas teorias e analisar os resultados. Esta abordagem transforma a aprendizagem num processo de descoberta, onde os alunos constroem ativamente conhecimento em vez de o receberem passivamente. Por exemplo, os alunos podem perguntar: "Será que uma máquina distingue entre uma voz feliz e uma voz triste?" e depois criar um projeto áudio para explorar essa questão.
- **Incentive a criatividade e a inovação:** A plataforma oferece uma via única para os alunos expressarem a sua criatividade e inovarem. Os alunos podem conceber projetos originais que aplicam ML para resolver problemas identificados ou criar novas experiências interativas. Esta ênfase na criatividade prepara os alunos para serem engenhosos e adaptáveis, fomentando um espírito empreendedor. Permitir que os alunos criem os seus próprios exercícios usando a Teachable Machine é um exemplo direto de como promover a aprendizagem autodirigida e o pensamento inovador.
- **Desenvolver competências de resolução de problemas e pensamento crítico:** Trabalhar com a Teachable Machine fortalece diretamente as competências de resolução de problemas e pensamento crítico dos alunos. Os alunos aprendem a decompor tarefas complexas, analisar dados, identificar padrões e conceber soluções lógicas. Também avaliam a eficácia dos seus modelos, identificam áreas a melhorar e refinam iterativamente as suas abordagens. Este processo iterativo, que envolve resolução de problemas e refinamento, é fundamental para dominar desafios complexos.

🗺️ **Mapeamento de competências:**

Ao defender a integração da IA no seu currículo, destaque estas competências essenciais desenvolvidas através da Teachable Machine:

- **Pensamento crítico e depuração:** Analisar porque é que um modelo comete erros de classificação e modificar sistematicamente os dados para melhorar a precisão.
- **Literacia de dados:** Compreender em primeira mão que o 'conhecimento' das máquinas depende inteiramente da qualidade, equilíbrio e diversidade dos dados fornecidos pelos humanos.
- **Resolução colaborativa de problemas:** Trabalhar em equipa para atribuir funções (recolhedor de dados, formador, testador, apresentador) e resolver desafios técnicos.

## 6.3 Considerações éticas e uso responsável da IA na sala de aula

À medida que a IA se torna mais comum na educação, é crucial dar prioridade às considerações éticas e garantir o seu uso responsável e equitativo. Os professores desempenham um papel vital ao orientar os alunos para se tornarem cidadãos éticos no campo da IA.

- **Compreender as preocupações éticas na IA:** É importante discutir potenciais questões éticas que surgem dos sistemas de IA.
    - **Viés e justiça:** Os sistemas de IA podem, por vezes, perpetuar ou até amplificar os vieses sociais existentes presentes nos dados em que são treinados. É fundamental ajudar os aprendentes a compreender como o viés pode entrar nos modelos de IA (por exemplo, a partir de dados enviesados ou algoritmos falhos). Incentivar o pensamento crítico para mitigar o viés e promover a justiça nas aplicações de IA é um passo fundamental.
    - **Privacidade e segurança dos dados:** O uso da IA na educação envolve frequentemente a recolha e utilização dos dados dos alunos. Enfatizar a importância da privacidade e segurança dos dados, garantindo que a informação dos alunos é protegida e gerida de forma responsável. É necessário discutir os riscos potenciais de violações de dados e a importância de práticas responsáveis de manuseamento dos dados.
    - **Transparência e explicabilidade:** Explore o conceito de transparência na IA, que aborda o desafio de compreender como alguns modelos de IA tomam decisões.

Discutir a necessidade de IA explicável (XAI) fomenta o desejo por sistemas mais transparentes e compreensíveis.

- **Diretrizes éticas para o uso da IA na educação:** As diretrizes práticas garantem a integração responsável da IA na sala de aula.
    - **Recolha e utilização responsável de dados:** Ao recolher dados, especialmente imagens, áudios ou poses de indivíduos, é imperativo obter consentimento informado. Os estudantes devem estar plenamente conscientes de como os seus dados serão usados e armazenados. Para projetos que envolvam crianças, o consentimento dos pais ou tutores legais é essencial. Também se recomenda evitar informações pessoais identificáveis (PII), a menos que seja estritamente necessário.
    - **Promova a justiça e a justiça nas aplicações de IA:** Procure garantir a diversidade nos conjuntos de dados para mitigar o viés. Esteja atento às potenciais fontes de viés durante a recolha de dados e tome medidas para as abordar. Avalie regularmente o desempenho em justiça do seu modelo e identifique quaisquer potenciais vieses.
    - **Fomentar o pensamento crítico sobre a ética da IA:** Os estudantes devem participar em discussões sobre as implicações éticas da IA, promovendo o pensamento crítico e a tomada de decisões responsáveis. Isto inclui temas como o impacto da IA na sociedade e na força de trabalho, os potenciais riscos e benefícios, e a importância de usar a IA para o bem. É vital formar os alunos no uso responsável da IA e na consciência do plágio, especialmente com ferramentas como o ChatGPT.
    - **Critérios de avaliação: Avalie o processo de aprendizagem:** Em vez de avaliar apenas com base no facto de o modelo final atingir elevada precisão, avalie os alunos com base na sua compreensão do ciclo de aprendizagem automática:
        1. **Identificação de vieses:** O aprendiz identificou potenciais fontes de viés ou desequilíbrio no seu conjunto de dados inicial?
        2. **Refinamento iterativo**: Quantas vezes a equipa reviu e melhorou o seu conjunto de dados após os testes falharem?
        3. **Clareza conceptual:** O aprendiz pode explicar a diferença entre os "Dados de Treino" e a "Entrada de Teste"?

## 6.4 Enfrentar desafios comuns

Integrar ferramentas de IA/ML na sala de aula, embora altamente benéfico, apresenta frequentemente um conjunto único de desafios para os professores. As perceções de inúmeros

educadores destacam barreiras comuns e oferecem sugestões práticas para as superar. Abordar estas questões de forma proativa garante um processo de integração mais fluido e eficaz.

- **Falta de formação prática:** Muitos professores relatam uma barreira significativa na forma de formação prática insuficiente em ferramentas de IA. Para responder a esta situação, são altamente recomendados módulos de formação especializados e práticos, adaptados a disciplinas e faixas etárias específicas. Workshops presenciais são particularmente valiosos durante a fase inicial de adoção, complementados por cursos online contínuos para desenvolvimento especializado e profissional contínuo.
- **Acesso limitado a dispositivos e à internet:** Um desafio generalizado identificado pelos educadores é o acesso insuficiente a ferramentas tecnológicas, incluindo dispositivos atualizados e ligação fiável à internet nas escolas. Para mitigar isto, é crucial melhorar a infraestrutura escolar e garantir o acesso equitativo a recursos de alta tecnologia, como tablets, óculos de realidade virtual e largura de banda adequada para a internet. Políticas que defendem o acesso gratuito a ferramentas digitais e licenças de aplicações também podem reduzir barreiras à adoção.

💡 Dica do professor:

**O plano de contingência "Plano B":** Se a internet da escola abrandar ou as webcams falharem durante as aulas, use estas abordagens alternativas:

- **Conjuntos de dados offline pré-carregados:** Mantenha uma pasta com imagens ou ficheiros de áudio pré-selecionados armazenados numa pen USB para que os alunos possam usar a opção 'Upload' em vez de gravação ao vivo via webcam ou microfone.
- **IA analógica ('Aprendizagem Automática Humana'):** Se a tecnologia falhar completamente, realiza-se uma atividade de simulação humana onde um aluno desempenha o papel de 'Algoritmo' e os colegas apresentam exemplos de cartões desenhados à mão para ver se o 'Algoritmo' consegue inferir a regra de ordenação.

- **Restrições de tempo para a integração da IA:** Os professores expressam frequentemente preocupações com horários apertados e exigências curriculares que limitam o seu tempo para explorar e adaptar ferramentas de IA. Para resolver esta questão, é necessário reservar tempo específico de desenvolvimento profissional para workshops de IA, permitindo que os professores se familiarizem com aplicações práticas. Fornecer materiais de aprendizagem pré-planeados, como guias ou manuais, também pode reduzir significativamente o tempo de planeamento.

- **Baixa literacia digital e falta de confiança:** Alguns educadores enfrentam desafios relacionados com a sua própria literacia digital e confiança na utilização eficaz das ferramentas de IA. Para ultrapassar isto, é altamente benéfico fornecer mentoria e plataformas de partilha entre pares. Nomear mentores ou coordenadores de IA nas escolas pode oferecer apoio e orientação sempre que necessário. Uma cultura que acolhe a IA, apoiada por iniciativas da gestão escolar, também constrói confiança e incentiva o uso responsável.
- **Preocupações éticas e falta de políticas:** Preocupações relativamente ao uso ético da IA, especialmente no caso de alunos mais jovens, e ao risco de uso indevido, como plágio, são significativas. É essencial incorporar diretrizes e políticas éticas claras para o uso da IA nos currículos de formação e nas políticas digitais a nível escolar. Formar os próprios alunos sobre o uso responsável da IA e aumentar a consciencialização para o plágio é também uma estratégia chave.
- **Dificuldades técnicas e falta de suporte de TI:** Os professores frequentemente enfrentam dificuldades técnicas, como falhas de software e problemas de acesso à internet. Embora muitos sejam engenhosos, confiando em investigação pessoal ou apoio entre pares, a necessidade de um suporte robusto de TI é evidente, especialmente nas escolas que não possuem departamentos de TI dedicados. Melhorar o suporte técnico fornecido por departamentos de TI ou técnicos especializados pode mitigar estes desafios comuns.

Ao enfrentar estes desafios identificados com apoio direcionado, infraestruturas melhoradas e desenvolvimento profissional contínuo, a integração bem-sucedida e sustentável das ferramentas de IA/ML nas salas de aula torna-se um objetivo mais alcançável.

# Módulo 7: Recursos e Apoio: O Seu Guia para a Aprendizagem Contínua

Iniciar a jornada de integração da IA e do Machine Learning no seu ensino é um processo contínuo. Este módulo serve como guia para a aprendizagem contínua e apoio, fornecendo referências a recursos online essenciais, caminhos para formação contínua em IA/AA e métodos para se manter atualizado com o panorama em constante evolução da tecnologia educativa.

## 7.1 Recursos Online para Máquina Aprendível

Existe uma grande variedade de recursos online para o apoiar na utilização do Teachable Machine. Estas plataformas oferecem documentação, tutoriais e comunidades onde pode encontrar respostas, inspirar-se e conectar-se com outros educadores.

- **Documentação Oficial da Máquina Teachable:** Para a informação mais precisa e atualizada sobre a ferramenta, consulte a sua documentação oficial. Este recurso fornece guias abrangentes sobre funcionalidades, resolução de problemas e melhores práticas diretamente dos seus criadores.
- **Tutoriais e exemplos:** Numerosos tutoriais online e projetos de exemplo demonstram várias aplicações do Teachable Machine. Estes podem ser encontrados em plataformas como o YouTube, blogues educativos ou sites especializados em educação tecnológica. Explorá-los pode despertar novas ideias e oferecer abordagens alternativas para criar projetos.
- **Fóruns comunitários e grupos de apoio:** Envolver-se com comunidades dedicadas à IA na educação ou com utilizadores do Teachable Machine oferece um apoio inestimável. Estes fóruns permitem-lhe colocar perguntas, partilhar as suas experiências, aprender com os colegas e encontrar soluções para desafios específicos que possa encontrar. Procure grupos online em plataformas de redes sociais ou fóruns dedicados à tecnologia educativa.
- **Plataformas oficiais e educativas recomendadas**
    - Google Teachable Machine: Link
    - Google for Education – Recursos de IA: Link
    - Google Grow: Link
    - IA. Google: Link
    - Iniciativa AI4K12: Link
    - European Schoolnet – Kit de Ferramentas de IA na Educação: Link
    - UNESCO – Diretrizes para IA na Educação: Link

## 7.2 Aprendizagem Adicional sobre IA e Aprendizagem Automática

O campo da Inteligência Artificial e do Machine Learning está em constante evolução. A aprendizagem contínua garante que se mantém atualizado e aprofunda a sua compreensão destas tecnologias transformadoras. Considere estas vias para alargar o seu conhecimento para além deste manual de jogadas.

- **Livros e artigos recomendados:** Existe uma vasta literatura sobre IA e ML. Procure livros introdutórios sobre IA para educadores ou artigos em revistas de tecnologia educativa de renome. Estes recursos frequentemente fornecem uma compreensão teórica mais profunda e perspetivas sobre as implicações pedagógicas.
- **Cursos e plataformas online:** Muitas plataformas reputadas oferecem cursos online gratuitos ou pagos sobre IA e ML, adaptados a vários níveis de especialização. Sites como Coursera, edX, Google AI for Educators ou Scratch com extensões de IA oferecem percursos de aprendizagem estruturados. Estes cursos podem ajudar a consolidar conhecimentos básicos e introduzir conceitos mais avançados
- **Organizações e iniciativas educativas:** Várias organizações dedicam-se a promover a literacia em IA e a sua integração na educação. Participar nestas iniciativas pode proporcionar acesso a investigação de ponta, programas-piloto e oportunidades de networking com profissionais com ideias semelhantes. Procure associações locais ou nacionais de tecnologia educativa.
- **Desenvolvimento profissional e MOOCs:** Estas plataformas dão acesso a ideias de aulas, diretrizes éticas, conjuntos de dados abertos e materiais de formação de professores adaptados a diferentes níveis de ensino.
    - Elementos da IA – Universidade de Helsínquia (Gratuito) - Link
    - IA para Todos – Coursera (Andrew Ng) – Link
    - IA na Educação – FutureLearn - Link
    - Universidade de Helsínquia – Construção de IA - Link
    - Especialização «Google AI Essentials» - Link
    - Google Grow – Experimente IA – Link

## 7.3 Apoio Contínuo e Atualizações

Manter-se atualizado com os desenvolvimentos em IA e Aprendizagem Automática é crucial para uma integração eficaz na sala de aula. O envolvimento ativo com a comunidade e os mecanismos de feedback garantem apoio contínuo e melhoria dos recursos.

- **Acompanhar os desenvolvimentos da Teachable Machine:** A própria plataforma Teachable Machine é periodicamente atualizada, introduzindo novas funcionalidades ou melhorando as existentes. Consultar regularmente o site oficial da Teachable Machine ou subscrever as suas newsletters garante que se mantém atualizado com as últimas alterações e pode adaptar o seu ensino em conformidade.
- **Conecte-se com especialistas e educadores:** Construir uma rede com especialistas em IA e outros educadores que estão a integrar a IA nas suas salas de aula proporciona um sistema de apoio valioso. Isto pode ser alcançado através de workshops de desenvolvimento profissional, conferências educativas ou comunidades online. Partilhar experiências e desafios conduz frequentemente a soluções colaborativas e novas perspetivas.
    - **Comunidades de educadores e redes colaborativas:** Incentive os professores a participar em MOOCs ou webinars e integre as reflexões resultantes dessas experiências nas suas práticas de ensino.
        - Redes de Professores da European Schoolnet (EUN).
        - Projetos eTwinning sobre literacia digital e IA.
        - Grupos de educadores de IA no Facebook e LinkedIn.
        - Redes nacionais e locais de parceiros Erasmus+.
        - Comunidade de Educadores OpenAI.
- **Dê feedback e contribua para a comunidade:** A sua experiência como educador a usar a Teachable Machine é inestimável. Dar feedback aos criadores da ferramenta ou do projeto M{AI}L ajuda a melhorar os recursos para os outros. Partilhar os seus planos de aula, exercícios ou ideias de projetos bem-sucedidas com comunidades ou plataformas educativas também enriquece a base de conhecimento coletiva.

## 7.4 Kits Práticos de Ferramentas de IA e Software Educativo para a Sala de Aula

Embora a Teachable Machine sirva como um ponto de entrada ideal e sem código para a introdução do machine learning, estender a literacia em IA a contextos educativos mais amplos requer frequentemente a integração de ferramentas complementares. A utilização de várias plataformas permite aos educadores ligar conceitos de IA à programação criativa, artes visuais, ambientes virtuais imersivos e narrativa de dados em diferentes faixas etárias de aprendentes.

Para expandir as experiências de aprendizagem para além dos modelos de avaliação baseados na web, os professores podem incorporar os seguintes kits práticos nas suas atividades STEAM e interdisciplinares:

- **Scratch with AI Extensions (MIT):** Um ambiente criativo de programação baseado em blocos que permite a alunos do ensino básico e secundário programar jogos e animações interativas baseados em visão computacional e modelos de reconhecimento áudio.
- **PictoBlox com extensões de IA e ML:** Um software avançado de programação gráfica baseado em Python, concebido para crianças e jovens explorarem robótica, reconhecimento facial e aplicações inteligentes de hardware.
- **Delightex Edu e Merge Cube:** Ambientes de aprendizagem de Realidade Aumentada (AR) e Realidade Virtual (VR) que permitem aos alunos visualizar, manipular e interagir com objetos 3D complexos e simulações espaciais baseadas em IA.
- **Teachable Machine combinado com Google Colab:** Um caminho de transição para estudantes do ensino secundário que passam da construção de modelos visuais sem código para a programação em Python e bibliotecas de machine learning.
- **Canva for Education:** Uma plataforma de design digital que apoia a narrativa visual de dados, a criação de infográficos e a integração responsável de media assistidos por IA para apresentações de projetos estudantis.
- **Adobe Firefly:** Uma ferramenta de IA generativa focada nas artes criativas que oferece um quadro seguro para debater geração responsável de imagens, engenharia de prompts e autoria digital na sala de aula.

A integração destas ferramentas permite aos educadores demonstrar a versatilidade da inteligência artificial para além dos exercícios isolados de aprendizagem automática, promovendo a criatividade multidisciplinar através da arte, do design e da programação interativa.

## 7.5 Quadros Éticos Globais e Diretrizes de Política sobre IA

A reflexão ética deve permanecer no centro da educação em inteligência artificial. À medida que as tecnologias de IA se integram cada vez mais na vida pública, os educadores precisam de referenciais autoritativos para orientar as discussões em sala de aula sobre privacidade de dados, equidade algorítmica, transparência e direitos humanos.

Para fundamentar as discussões em sala de aula nas normas globais estabelecidas, os professores podem consultar e adaptar políticas internacionais chave e diretrizes éticas:

- **Recomendação da UNESCO sobre a Ética da Inteligência Artificial (2021):** Um quadro de consenso global que enfatiza a dignidade humana, as liberdades fundamentais, a proteção ambiental e a igualdade de género nos sistemas de IA. Link
- **Diretrizes Éticas para IA Confiável (Comissão Europeia, 2019):** Diretrizes europeias que destacam sete requisitos-chave para IA ética, incluindo autonomia humana, segurança técnica, privacidade, transparência e não discriminação. Link
- **Princípios da OCDE sobre IA (2019):** Princípios internacionais que defendem uma IA inovadora e de confiança que respeite os direitos humanos, os valores democráticos e o desenvolvimento social equitativo. Link
- **Relatórios do Conselho da Europa sobre IA e Direitos Humanos:** Recursos analíticos abrangentes que examinam o impacto dos algoritmos de aprendizagem automática na liberdade de expressão, educação e processos democráticos. Link

Os educadores podem usar estes quadros para iniciar debates significativos em sala de aula sobre cidadania digital, mitigação de preconceitos e proteção de dados.

Incentivar os alunos a avaliar criticamente como os algoritmos influenciam os feeds das redes sociais, os resultados da investigação e a tomada de decisões públicas promove cidadãos digitais informados, responsáveis e ativos.

## 7.6 Desenvolvimento de práticas sustentáveis e divulgação de projetos

Alcançar um impacto educativo duradouro requer ir além das atividades isoladas em sala de aula para estabelecer práticas de ensino sustentáveis em IA em toda a comunidade escolar. Incorporar a literacia em IA na cultura institucional quotidiana garante que os educadores se apoiem mutuamente e que as oportunidades de aprendizagem continuem a expandir-se ao longo do tempo.

Para criar um ambiente de aprendizagem de IA resiliente e sustentável, escolas e professores devem implementar as seguintes práticas estratégicas:

- **Redes locais de professores:** Estabeleça comunidades profissionais de aprendizagem na sua escola ou distrito local, onde educadores de diferentes áreas possam colaborar, partilhar planos de aula e resolver desafios técnicos.
- **Exposições e workshops escolares:** Organizar apresentações interativas para alunos, feiras de ciências com IA ou workshops liderados por pares, onde os alunos apresentam os seus modelos treinados e demonstram as suas competências de pensamento computacional a pais, líderes escolares e colegas.
- **Desenvolvimento profissional entre pares:** Facilite sessões internas de mentoria onde docentes com experiência no uso da Teachable Machine formam colegas que são novos na integração de tecnologias digitais.
- **Documentação e disseminação a nível europeu:** Documentar os resultados dos projetos, folhas de reflexão dos alunos e Planos de Unidade de Aprendizagem (LUPs) bem-sucedidos para partilhar em redes educativas internacionais, como plataformas Erasmus+ e comunidades europeias do Schoolnet.

# Conclusão: Capacitar os futuros alunos com IA

Agora completou uma jornada essencial no mundo da Inteligência Artificial e do Machine Learning, explorando especificamente como a Teachable Machine pode tornar-se um aliado poderoso na sua sala de aula. Este manual guiou-o pelos conceitos fundamentais de IA/AA, forneceu instruções passo a passo para criar projetos envolventes com imagens, áudio e poses, e apresentou estratégias práticas para os integrar em várias disciplinas.

Adotar estas tecnologias significa mais do que apenas adotar novas ferramentas; representa uma oportunidade profunda para transformar o ensino e a aprendizagem. Agora está pronto para desmistificar conceitos complexos para os seus alunos, despertar a sua curiosidade pela tecnologia e fomentar competências essenciais do século XXI, como resolução de problemas, criatividade e pensamento computacional. Preparar os alunos para usar estas tecnologias de forma responsável e eficaz torna-se um objetivo tangível ao seu alcance.

O projeto M{AI}L acredita no seu papel fundamental enquanto educadores na construção do futuro da educação. Encorajamo-lo a experimentar, inovar e adaptar estas estratégias ao seu ambiente único de sala de aula. Partilhe os seus sucessos, aprenda com os desafios e contribua para a comunidade crescente de professores que aproveitam a IA para o bem. Isto não marca um fim, mas sim o início entusiasmante da vossa jornada como educadores impulsionados por IA.

Estamos confiantes de que o seu trabalho inspirará uma nova geração de aprendentes, prontos para navegar e contribuir para um mundo cada vez mais moldado pela Inteligência Artificial. Obrigado por ser uma parte essencial desta iniciativa transformadora.