

Aula 21 – Aprendizado Supervisionado: Classificação

Você já parou para pensar em quantas decisões são tomadas automaticamente ao seu redor, baseadas em dados? Desde o e-mail que vai para a caixa de spam até a sugestão de um filme que você adora, há um processo inteligente em ação. No mundo do Big Data e Analytics, entender como essas decisões são feitas é crucial, e é exatamente isso que vamos explorar nesta aula: a **Classificação**.

Esta aula foi cuidadosamente desenhada para você, estudante universitário em busca de horas complementares valiosas, e para você, candidato a concurso público que precisa de um diferencial no currículo. Nosso objetivo é que, ao final desta jornada, você não apenas compreenda os conceitos fundamentais do Aprendizado Supervisionado de Classificação, mas também seja capaz de identificar suas aplicações práticas e interpretar seus resultados. Prepare-se para desmistificar termos como Matriz de Confusão e F1-Score, e ver como eles se conectam diretamente com o seu dia a dia e com as demandas do mercado de trabalho.

Nesta jornada, vamos construir nosso conhecimento passo a passo. Começaremos entendendo o que é classificação e por que ela é tão poderosa. Em seguida, mergulharemos em algoritmos populares como Árvores de Decisão e Regressão Logística, que são a espinha dorsal de muitas soluções de Inteligência Artificial e Machine Learning que você usa diariamente. Depois, aprenderemos a avaliar a performance desses modelos, utilizando métricas essenciais que garantem a confiabilidade das previsões. Por fim, exploraremos casos de uso reais que demonstram o impacto transformador da classificação em diversas áreas.

Para embarcar nesta aula, é útil que você já tenha uma noção básica sobre o que é Big Data e por que a análise de dados é tão importante. Se você já ouviu falar em Machine Learning ou Inteligência Artificial, ótimo! Caso contrário, não se preocupe: vamos conectar os pontos de forma clara, mostrando como a classificação é uma peça fundamental nesse universo.


DESENVOLVIMENTO

O Que É Classificação? Prever Categorias no Mundo dos Dados

Imagine que você está organizando sua caixa de e-mails. Alguns são importantes, outros são promoções e alguns, bem, são claramente spam. Como você decide qual e-mail vai para qual pasta? Você usa sua experiência, padrões que aprendeu ao longo do tempo: remetente, assunto, palavras-chave. No mundo dos dados, a **Classificação** faz exatamente isso, mas de forma automatizada e em escala massiva.

A classificação é uma das tarefas mais comuns e poderosas do **Aprendizado Supervisionado** em Machine Learning. O "supervisionado" aqui significa que o algoritmo aprende a partir de dados que já possuem um "rótulo" ou "resposta" correta. É como um estudante que aprende com um professor que já sabe as respostas. O objetivo é construir um modelo que, ao receber novos dados sem rótulo, consiga prever a qual categoria eles pertencem. Pense nisso como ensinar um sistema a identificar padrões para tomar decisões futuras.

A necessidade de classificar surge em inúmeros cenários. Em um banco, por exemplo, é preciso decidir se um cliente é um bom pagador ou se representa um risco de inadimplência. Em um hospital, é fundamental classificar se um paciente tem ou não uma determinada doença com base em seus sintomas e exames. Em ambos os casos, não estamos prevendo um valor numérico contínuo (como o preço de uma casa), mas sim uma categoria discreta: "bom pagador" ou "mau pagador", "doente" ou "saudável". Essa é a essência da classificação: transformar dados em decisões categóricas.



Classificação no Dia a Dia: Mais Perto do que Você Imagina

Você já se perguntou como o seu aplicativo de streaming de música sabe exatamente qual música sugerir para o seu humor atual? Ou como as redes sociais filtram conteúdo impróprio antes mesmo que você o veja? Por trás dessas "mágicas" digitais, frequentemente, está um modelo de classificação em ação. Ele aprendeu com milhões de interações anteriores a categorizar o que você gosta, o que é seguro ou o que é relevante.



Insight: A beleza da classificação reside em sua capacidade de transformar grandes volumes de dados brutos em insights acionáveis, automatizando processos que seriam impossíveis de gerenciar manualmente.

Com a crescente integração da **Inteligência Artificial e Machine Learning** em todas as esferas, a classificação se tornou uma ferramenta indispensável para extrair valor de dados, indo muito além da análise tradicional. Ela nos permite prever tendências, identificar anomalias e personalizar experiências em uma escala sem precedentes.

Imagine que você é um analista de marketing e precisa identificar quais clientes têm maior probabilidade de cancelar um serviço (churn). Um modelo de classificação pode analisar o histórico de uso, interações com o suporte e dados demográficos para prever essa probabilidade, categorizando os clientes em "alto risco de churn" ou "baixo risco de churn". Com essa informação, a equipe pode agir proativamente, oferecendo incentivos ou suporte especial para reter esses clientes. Essa é a força da classificação: não apenas prever, mas capacitar a tomada de decisão estratégica.

Desvendando Algoritmos Populares: Árvores de Decisão

Agora que entendemos o que é classificação e sua importância, vamos mergulhar em como ela realmente funciona, explorando alguns dos algoritmos mais populares. Começaremos com as **Árvores de Decisão**, um método intuitivo e poderoso que imita o processo de tomada de decisão humana. Pense em uma árvore de decisão como um fluxograma, onde cada "nó" representa uma pergunta sobre os dados e cada "ramo" representa uma possível resposta.

Imagine que você está tentando decidir se vai sair de casa para um piquenique. Sua decisão pode depender de várias coisas: "Está chovendo?" Se sim, você não vai. Se não, a próxima pergunta pode ser: "Está ensolarado?" Se sim, você vai. Se não, "Está nublado, mas sem chuva?" E assim por diante. Uma árvore de decisão funciona de forma muito similar, dividindo os dados em subconjuntos cada vez menores com base em características específicas, até que uma decisão final (a categoria) possa ser tomada.

O algoritmo constrói essa árvore automaticamente, escolhendo as perguntas (ou "atributos") que melhor separam os dados em grupos homogêneos. Por exemplo, para classificar se um e-mail é spam, a primeira pergunta pode ser: "O e-mail contém a palavra 'ganhe dinheiro'?" Se sim, ele segue um caminho; se não, segue outro. Cada caminho leva a uma folha da árvore, que é a previsão final: "spam" ou "não spam". A grande vantagem das árvores de decisão é sua interpretabilidade; é fácil visualizar e entender o caminho que levou a uma determinada classificação.

Árvores de Decisão em Ação: Um Exemplo Conceitual

Para ilustrar melhor, vamos pensar em um cenário de concessão de crédito. Um banco precisa decidir se aprova ou reprovava o pedido de empréstimo de um cliente. Uma **Árvore de Decisão** pode ser construída com base em dados históricos de clientes e suas respectivas classificações (bons pagadores/maus pagadores).

01

Pergunta Principal: Renda Mensal

O processo começaria com uma pergunta principal, talvez sobre a **renda mensal** do cliente. Se a renda for alta, o caminho da árvore pode levar a uma aprovação mais rápida ou a uma nova pergunta.

02

Análise de Histórico

Se a renda for baixa, a árvore pode perguntar sobre a **idade** do cliente ou se ele possui **outros empréstimos**. Cada resposta direciona o cliente para um novo nó.

03

Decisão Final

O cliente chega a uma "folha" da árvore, que é a decisão final: "Aprovar" ou "Reprovar".


A beleza desse método é que ele lida bem com dados complexos e pode identificar interações não lineares entre as variáveis. No entanto, árvores de decisão podem ser suscetíveis a **overfitting** (ajustar-se demais aos dados de treinamento, perdendo a capacidade de generalizar para novos dados) se não forem bem controladas. Para mitigar isso, técnicas como "poda" (remover ramos menos importantes) ou o uso de florestas aleatórias (conjuntos de várias árvores) são comuns. Sua simplicidade e poder de visualização as tornam uma excelente porta de entrada para o mundo dos algoritmos de classificação.

DESENVOLVIMENTO

Regressão Logística: Uma Abordagem Diferente para Classificação

Enquanto as Árvores de Decisão usam uma série de perguntas para categorizar, a **Regressão Logística** adota uma abordagem mais matemática, baseada em probabilidades. Apesar do nome "Regressão", ela é um algoritmo fundamental para problemas de classificação, especialmente quando temos duas categorias (classificação binária). Ela não prevê um valor contínuo, mas sim a **probabilidade** de um dado pertencer a uma das classes.

Imagine que você está tentando prever se um aluno será aprovado ou reprovado em uma disciplina. Você tem dados sobre as horas de estudo, notas anteriores e frequência. A Regressão Logística não vai dizer "sim" ou "não" diretamente, mas sim "há 85% de chance de aprovação" ou "há 20% de chance de aprovação". A partir dessa probabilidade, definimos um limiar (por exemplo, 50%): se a probabilidade for maior que 50%, classificamos como "aprovado"; caso contrário, "reprovado".

 **Conceito-chave:** Este algoritmo utiliza uma função matemática chamada **função sigmoide** para "espremer" qualquer valor numérico entre 0 e 1, que pode ser interpretado como uma probabilidade.

Quanto mais próximo de 1, maior a probabilidade de pertencer à classe positiva (por exemplo, "aprovado"); quanto mais próximo de 0, maior a probabilidade de pertencer à classe negativa. É uma ferramenta poderosa e amplamente utilizada por sua eficiência e por fornecer uma medida de confiança (a probabilidade) junto com a classificação.

Regressão Logística em Ação: Previsão de Churn

Vamos revisitar o exemplo de previsão de **churn** (cancelamento de serviço). Uma empresa de telecomunicações quer identificar clientes que provavelmente cancelarão seu plano. A **Regressão Logística** pode ser aplicada aqui para prever a probabilidade de um cliente sair.

Análise de Dados

O modelo analisaria diversas características do cliente, como tempo de contrato, uso de dados, número de chamadas para o suporte, reclamações, e até mesmo dados demográficos.

Cálculo de Probabilidade

Para cada cliente, o algoritmo calcularia uma probabilidade de churn. Por exemplo, um cliente pode ter 0.75 (75%) de probabilidade de cancelar, enquanto outro tem 0.10 (10%).

Classificação Final

Se o limiar for 0.5, o primeiro cliente seria classificado como "provável churn", e o segundo como "improvável churn".

A Regressão Logística é particularmente útil quando a relação entre as variáveis de entrada e a probabilidade de saída é linear (após a transformação pela função sigmoide). Ela é mais simples e rápida de treinar do que muitos outros algoritmos e oferece uma boa base para entender modelos mais complexos. Ao contrário das Árvore de Decisão, que criam divisões "duras", a Regressão Logística oferece uma transição mais suave entre as categorias, baseada na probabilidade.

Algoritmo	Conceito Base/Origem	Interpretabilidade	Exemplo de Uso
Árvore de Decisão	Fluxograma de perguntas e respostas	Alta, visualmente intuitiva	Concessão de crédito, diagnóstico de falhas
Regressão Logística	Probabilidade, função sigmoide	Média, baseada em coeficientes e probabilidades	Previsão de churn, detecção de spam

DESENVOLVIMENTO

A Importância de Avaliar: Entendendo a Matriz de Confusão

Depois de treinar um modelo de classificação, como sabemos se ele é bom? Como podemos confiar nas suas previsões? A resposta está na avaliação de desempenho. Não basta apenas que o modelo classifique; ele precisa classificar **corretamente** e, mais importante, de uma forma que seja útil para o problema que estamos tentando resolver. É aqui que entra a **Matriz de Confusão**, uma ferramenta essencial para entender os acertos e erros do nosso modelo.

Imagine que você está testando um novo sistema de segurança que detecta intrusos em sua casa. O sistema pode dizer "intruso" ou "não intruso". Na vida real, pode haver um intruso (verdadeiro) ou não (falso). O sistema pode acertar (detectar um intruso real) ou errar (disparar um alarme falso quando não há ninguém, ou pior, não detectar um intruso real). A Matriz de Confusão nos ajuda a organizar esses quatro cenários possíveis.

A Matriz de Confusão é uma tabela que resume o desempenho de um algoritmo de classificação em um conjunto de dados de teste. Ela compara as classificações **preditas** pelo modelo com as classificações **reais** (os rótulos verdadeiros) dos dados. É a base para calcular todas as métricas de desempenho mais importantes, oferecendo uma visão detalhada de onde o modelo está acertando e, crucialmente, onde está errando. Sem ela, estaríamos voando às cegas, sem saber a verdadeira eficácia do nosso sistema.

Matriz de Confusão: Os Quatro Cenários Cruciais

A Matriz de Confusão é geralmente estruturada para problemas de classificação binária (duas classes, por exemplo, "Positivo" e "Negativo"). Ela nos mostra quatro resultados possíveis, que são a base para todas as métricas que veremos a seguir:

1

Verdadeiro Positivo (VP)

O modelo previu "Positivo" e a classe real era "Positivo". (Acerto: o sistema de segurança detectou um intruso real).

2

Verdadeiro Negativo (VN)

O modelo previu "Negativo" e a classe real era "Negativo". (Acerto: o sistema de segurança não disparou quando não havia intruso).

3


Falso Positivo (FP)

O modelo previu "Positivo" mas a classe real era "Negativo". (Erro Tipo I: o sistema de segurança disparou um alarme falso).

4

Falso Negativo (FN)

O modelo previu "Negativo" mas a classe real era "Positivo". (Erro Tipo II: o sistema de segurança não detectou um intruso real).

 **Exemplo prático:** Pense na detecção de spam. Um VP seria um e-mail de spam corretamente identificado como spam. Um VN seria um e-mail legítimo corretamente identificado como não-spam. Um FP seria um e-mail legítimo erroneamente classificado como spam (e-mail importante vai para a lixeira!). E um FN seria um e-mail de spam que passou despercebido para sua caixa de entrada.

A importância de cada tipo de erro (FP vs. FN) varia muito dependendo do contexto, e a Matriz de Confusão nos permite quantificá-los.

DESENVOLVIMENTO

Métricas Essenciais: Acurácia, Precisão, Recall e F1-Score

Com a Matriz de Confusão em mãos, podemos agora calcular métricas mais sofisticadas que nos dão uma visão mais completa do desempenho do nosso modelo. Não existe uma única métrica "melhor" para todas as situações; a escolha depende do problema de negócio e do custo associado a cada tipo de erro (Falso Positivo ou Falso Negativo).

O que é pior?

Imagine que você é um médico desenvolvendo um modelo para diagnosticar uma doença rara e grave.

Falso Positivo: Dizer a alguém que ele tem a doença quando não tem

Falso Negativo: Dizer que não tem quando na verdade tem (consequências devastadoras!)

É por isso que precisamos de um arsenal de métricas. A **Acurácia** nos dá uma visão geral, mas pode ser enganosa em dados desbalanceados. A **Precisão** e o **Recall** nos ajudam a entender o desempenho do modelo em relação a cada classe, focando em diferentes tipos de erros. E o **F1-Score** tenta equilibrar esses dois últimos, oferecendo uma métrica única que considera ambos. Vamos explorar cada uma delas.

Acurácia e Precisão: O Que Elas Realmente Medem



Acurácia

A **Acurácia** é talvez a métrica mais intuitiva e a primeira que vem à mente. Ela mede a proporção de previsões corretas sobre o total de previsões. Em outras palavras, quantos acertos (VP + VN) o modelo teve em relação a todas as classificações (VP + VN + FP + FN).

$$\text{Acurácia} = (VP + VN) / (VP + VN + FP + FN)$$



Precisão

A **Precisão** (ou Valor Preditivo Positivo) foca nos casos que o modelo classificou como "Positivo". Ela responde à pergunta: "Dos que o modelo classificou como Positivos, quantos realmente eram Positivos?"

$$\text{Precisão} = VP / (VP + FP)$$



⚠ Cuidado com a Acurácia! Embora pareça ótima, a acurácia pode ser enganosa. Se você tem um modelo que detecta uma doença que afeta apenas 1% da população, um modelo que sempre diz "não tem a doença" terá 99% de acurácia, mas será completamente inútil! Ele nunca detectará um caso real.

Voltando ao exemplo do spam: uma alta precisão significa que, quando o modelo diz que um e-mail é spam, ele provavelmente está certo. Isso é importante para evitar que e-mails importantes sejam enviados para a caixa de spam (reduzir Falsos Positivos). Se a precisão for baixa, você passará muito tempo resgatando e-mails importantes da lixeira.

DESENVOLVIMENTO

Recall e F1-Score: Capturando a Totalidade e o Equilíbrio

Enquanto a Precisão se preocupa com a qualidade das previsões positivas, o **Recall** (ou Sensibilidade, ou Taxa de Verdadeiros Positivos) se preocupa com a quantidade. Ele responde à pergunta: "Dos casos que realmente eram Positivos, quantos o modelo conseguiu identificar?"

$$\text{Recall} = \text{VP} / (\text{VP} + \text{FN})$$

No exemplo da detecção de spam, um alto recall significa que o modelo consegue identificar a maioria dos e-mails de spam existentes. Isso é importante para garantir que sua caixa de entrada fique limpa (reduzir Falsos Negativos). No caso do diagnóstico médico de uma doença grave, um alto recall é vital para não deixar nenhum paciente doente sem diagnóstico.

Muitas vezes, há um **trade-off** entre Precisão e Recall: aumentar um pode diminuir o outro. É como uma balança. Se você quer ter certeza absoluta de que cada e-mail que você marca como spam é realmente spam (alta Precisão), você pode acabar deixando alguns spams passarem (baixo Recall). Para lidar com esse dilema, usamos o **F1-Score**.

O **F1-Score** é a média harmônica da Precisão e do Recall. Ele oferece uma única métrica que tenta equilibrar ambos, sendo particularmente útil quando as classes são desbalanceadas.

$$\text{F1-Score} = 2 * (\text{Precisão} * \text{Recall}) / (\text{Precisão} + \text{Recall})$$

Um F1-Score alto indica que o modelo tem tanto boa Precisão quanto bom Recall, sendo uma métrica robusta para a avaliação geral do desempenho do classificador.

Casos de Uso Reais: Onde a Classificação Brilha

A teoria é fascinante, mas a verdadeira magia da classificação se revela em suas aplicações práticas. Ela é a força motriz por trás de muitas das inovações que moldam nosso mundo digital e físico. Vamos explorar alguns dos casos de uso mais impactantes, que demonstram a versatilidade e o poder desses algoritmos.



Detecção de Spam

Um dos exemplos mais clássicos e cotidianos. Seu provedor de e-mail utiliza modelos de classificação para analisar cada mensagem recebida e decidir se ela é legítima ou indesejada. O modelo aprende com milhões de e-mails já classificados (supervisionado!) a identificar padrões como palavras-chave suspeitas, remetentes incomuns ou links maliciosos. Uma alta precisão aqui é crucial para não perder e-mails importantes, enquanto um bom recall garante que sua caixa de entrada não seja inundada por lixo.



Análise de Sentimento

Empresas querem saber o que os clientes pensam de seus produtos ou serviços. Modelos de classificação podem analisar textos (tweets, avaliações de produtos, comentários em redes sociais) e categorizá-los como "positivo", "negativo" ou "neutro". Isso permite que as empresas monitorem a percepção da marca em tempo real, identifiquem problemas rapidamente e respondam de forma proativa. É uma ferramenta poderosa para entender a voz do cliente em escala.

Casos de Uso Reais: Da Saúde à Segurança Digital

A classificação também desempenha um papel vital em áreas de alta responsabilidade, como o **diagnóstico médico**. Modelos podem ser treinados com dados de pacientes (sintomas, resultados de exames, histórico médico) para auxiliar médicos a classificar se um paciente tem ou não uma determinada doença, ou qual o risco de desenvolver uma condição. Isso não substitui o julgamento médico, mas atua como uma ferramenta de apoio, aumentando a precisão e a velocidade dos diagnósticos, especialmente em doenças raras ou complexas.



Processamento em Tempo Real

Sistemas de segurança que detectam comportamentos anômalos em câmeras de vigilância instantaneamente





Edge Computing

Sensores em máquinas industriais que classificam falhas antes que elas ocorram, tudo processado na "borda" da rede



Segurança

Detecção de fraudes em transações financeiras ou identificação de ameaças cibernéticas

  **Ética e Responsabilidade:** A **Governança, Ética e Privacidade de Dados** também são considerações importantes. Ao construir modelos de classificação, é fundamental garantir que eles não perpetuem ou amplifiquem vieses existentes nos dados de treinamento, o que poderia levar a decisões injustas ou discriminatórias. A transparência e a interpretabilidade dos modelos, como as Árvores de Decisão, tornam-se ainda mais valiosas nesse contexto.

A classificação é uma ferramenta poderosa, e seu uso responsável é tão importante quanto sua capacidade técnica.

Conectando os Pontos: O Poder da Classificação

Chegamos ao fim de nossa jornada pela Classificação, um pilar fundamental do Aprendizado Supervisionado. Vimos que classificar é mais do que apenas categorizar; é transformar dados em decisões inteligentes, automatizando processos e gerando insights valiosos. Exploramos como algoritmos como Árvores de Decisão e Regressão Logística operam, cada um com sua lógica e aplicações específicas. E, crucialmente, aprendemos a avaliar a performance desses modelos através da Matriz de Confusão e métricas como Acurácia, Precisão, Recall e F1-Score, entendendo que a escolha da métrica certa depende do contexto e do custo dos erros.

Em prática

A capacidade de entender e aplicar modelos de classificação é uma habilidade altamente valorizada no mercado de trabalho atual. Seja para otimizar campanhas de marketing, melhorar diagnósticos médicos ou fortalecer a segurança digital, a classificação está no cerne da inovação impulsionada por dados. Ao dominar esses conceitos, você estará apto a contribuir significativamente em qualquer área que lide com grandes volumes de informação.

Autoavaliação

- Qual das seguintes afirmações melhor descreve o objetivo principal da Classificação no Aprendizado Supervisionado?
 - Prever um valor numérico contínuo com base em dados históricos.
 - Agrupar dados semelhantes sem rótulos pré-definidos.
 - Atribuir dados a categorias discretas com base em padrões aprendidos.
 - Reduzir a dimensionalidade de grandes conjuntos de dados.
- Em um modelo de detecção de fraude, um "Falso Negativo" (FN) ocorreria se:
 - Uma transação legítima fosse classificada como fraudulenta.
 - Uma transação fraudulenta fosse corretamente identificada como fraudulenta.
 - Uma transação legítima fosse corretamente identificada como legítima.
 - Uma transação fraudulenta fosse classificada como legítima.
- Qual métrica é mais indicada quando há um grande desbalanceamento entre as classes e é crucial equilibrar a capacidade do modelo de identificar todos os casos positivos (Recall) e garantir que as previsões positivas sejam realmente positivas (Precisão)?
 - Acurácia
 - Precisão
 - Recall
 - F1-Score
- As Árvores de Decisão são frequentemente elogiadas por qual característica?
 - Sua alta velocidade de treinamento em grandes volumes de dados.
 - Sua interpretabilidade e facilidade de visualização do processo de decisão.
 - Sua capacidade de lidar exclusivamente com dados numéricos contínuos.
 - Sua resistência natural ao overfitting sem a necessidade de poda.
- Explique, com suas palavras, a diferença entre Precisão e Recall em um contexto de diagnóstico médico de uma doença grave. Qual métrica seria mais crítica e por quê?

Gabarito

1

Resposta

c)

2

Resposta

d)

3

Resposta

d)

4

Resposta

b)

5

Resposta Dissertativa

Precisão mede a proporção de diagnósticos positivos que estavam corretos (dos que o modelo disse que tinham a doença, quantos realmente tinham). **Recall** mede a proporção de pacientes realmente doentes que foram corretamente diagnosticados (dos que realmente tinham a doença, quantos o modelo conseguiu identificar). Em uma doença grave, o **Recall** seria mais crítico, pois um Falso Negativo (não diagnosticar alguém que está doente) pode ter consequências fatais.

Próxima Aula

Aula 22 – Aprendizado Não Supervisionado: Clusterização

Na próxima aula, daremos um passo além no universo do Machine Learning, explorando o **Aprendizado Não Supervisionado**. Se na classificação o modelo aprende com rótulos, na clusterização ele descobre padrões e grupos em dados sem rótulos prévios. Prepare-se para desvendar como os algoritmos encontram estruturas ocultas e organizam o caos dos dados.

Recursos Adicionais

- **Livro "Mãos à Obra: Machine Learning com Scikit-Learn, Keras e TensorFlow" de Aurélien Géron:** Para aprofundar nos exemplos práticos e implementação de algoritmos.
- **Curso online "Machine Learning" da Coursera (Andrew Ng):** Uma base teórica sólida e amplamente reconhecida para os fundamentos do ML.
- **Documentação oficial do Scikit-learn (Python):** Para explorar as implementações de Árvores de Decisão e Regressão Logística, além das métricas de avaliação.

📌 **NOTA IMPORTANTE:** As informações técnicas desta aula estão atualizadas até 2025. Consulte sempre fontes oficiais e a documentação das bibliotecas e frameworks para verificar alterações e as versões mais recentes.