

Exemplo de Exame - Respostas

Set A
Versão 2.0

ISTQB® AI Testing Syllabus

Compatível com a versão 2.0 do syllabus

International Software Testing Qualifications Board



Aviso de Direitos Autorais

Aviso de direitos autorais © International Software Testing Qualifications Board (doravante denominado ISTQB®).

ISTQB® é uma marca registrada do International Software Testing Qualifications Board.

Todos os direitos reservados.

Os autores transferem por meio deste os direitos autorais para o ISTQB®. Os autores (como atuais detentores dos direitos autorais) e o ISTQB® (como futuro detentor dos direitos autorais) concordaram com as seguintes condições de uso:

Trechos deste documento, para uso não comercial, podem ser copiados desde que a fonte seja citada.

Qualquer Provedor de Treinamento Credenciado pode utilizar este exame de amostra em seu curso de treinamento, desde que os autores e o ISTQB® sejam citados como fonte e detentores dos direitos autorais do exame de amostra e desde que qualquer divulgação desse curso de treinamento seja feita somente após o recebimento do credenciamento oficial dos materiais de treinamento por um Conselho Membro reconhecido pelo ISTQB®.

Qualquer indivíduo ou grupo de indivíduos pode utilizar este exame de amostra em artigos e livros, desde que os autores e o ISTQB® sejam citados como fonte e detentores dos direitos autorais do exame de amostra.

Qualquer outro uso deste exame de amostra é proibido sem a prévia obtenção da aprovação por escrito do ISTQB®.

Qualquer Conselho Membro reconhecido pelo ISTQB® pode traduzir este exame de amostra, desde que reproduza o Aviso de Direitos Autorais acima mencionado na versão traduzida do exame de amostra.

Responsabilidade pelo documento

O Grupo de Trabalho de Exames do ISTQB® é responsável por este documento.

Este documento é mantido por uma equipe central do ISTQB® composta pelo Grupo de Trabalho de Syllabus e pelo Grupo de Trabalho de Exames.

Agradecimentos

Este documento foi produzido por uma equipe central do ISTQB®: Klaudia Dussa-Zieger, Stuart Reid, Vipul Koch, Kyle Siemens, Qin Liu, Werner Henschelchen, Jarosław Hryszko

A equipe principal agradece à equipe de revisão do Grupo de Trabalho de Exames, ao Grupo de Trabalho de Syllabus e aos Conselhos de Membros por suas sugestões e contribuições.

Histórico de revisões

Versão	Data	Observações
1.0	01/10/2021	Lançamento para GA
2.0 Beta	05/01/2026	Revisão da versão beta
2.0	17/04/2026	Lançamento para o público geral

Índice

Aviso de Direitos Autorais	2
Responsabilidade pelo documento	2
Agradecimentos	2
Histórico de revisões	3
Índice	4
Introdução	6
Objetivo deste documento	6
Instruções	6
Gabarito	7
Respostas	8
1	8
2	8
3	9
4	9
5	10
6	10
7	11
8	12
9	12
10	13
11	13
12	14
13	14
14	15
15	15
16	15
17	16
18	16
19	17
20	17
21	18
22	18
23	18
24	18
25	19
26	19
27	20
28	20
29	21
30	21
31	21
32	22
33	22
34	23
35	23
36	24
37	24
38	24
39	25
40	25
Apêndice: Respostas a perguntas adicionais	27
Chave de respostas	28



Respostas..... 29

A1..... 29

A2..... 31

A3..... 31

A4..... 31

A5..... 33

A6..... 34

Introdução

Objetivo deste documento

As questões e respostas de exemplo, bem como as justificativas associadas, contidas neste exame modelo foram elaboradas por uma equipe de especialistas na matéria e redatores de questões experientes com o objetivo de:

- Auxiliar os Conselhos Membros e os Conselhos Examinadores do ISTQB® em suas atividades de elaboração de questões
- Fornecer aos provedores de treinamento e aos candidatos a exames exemplos de questões de exame

Essas questões não podem ser utilizadas tal como estão em nenhum exame oficial.

Observe que os exames reais podem incluir uma ampla variedade de questões, e este exame modelo **não** tem como objetivo incluir exemplos de todos os tipos, estilos ou comprimentos de questões possíveis; além disso, este exame modelo pode ser mais difícil ou menos difícil do que qualquer exame oficial.

Instruções

Neste documento, você encontrará:

- Tabela de respostas, incluindo para cada resposta correta:
 - Nível K, Objetivo de Aprendizagem e Valor em pontos
- Conjuntos de respostas, incluindo para todas as questões:
 - Resposta correta
 - Justificativa para cada opção de resposta
 - Nível K, Objetivo de Aprendizagem e Valor em pontos
- Conjuntos de respostas adicionais, incluindo para todas as questões [não se aplica a todas as provas de exemplo]:
 - Resposta correta
 - Justificativa para cada opção de resposta
 - Nível K, Objetivo de aprendizagem e Valor em pontos
- *As perguntas estão contidas em um documento separado*

Gabarito

Número da questão (#)	Resposta correta	LO	Nível K	Pontos
1	a	AI-1.1.1	K2	1
2	c, e	AI-1.1.2	K2	1
3	a	AI-1.1.3	K2	1
4	b	AI-1.1.4	K2	1
5	a	AI-1.1.5	K2	1
6	b	AI-1.1.6	K2	1
7	c	AI-2.1.1	K2	1
8	b	AI-2.1.2	K2	1
9	c	AI-2.2.1	K2	1
10	a	AI-3.1.1	K2	1
11	d	AI-3.1.2	K2	1
12	d	AI-3.1.4	K2	1
13	c	AI-3.2.1	K2	1
14	b	AI-3.2.3	K2	1
15	c	AI-3.3.1	K3	2
16	a	AI-3.4.1	K2	1
17	a	AI-4.1.1	K2	1
18	b	AI-4.1.2	K2	1
19	b	AI-4.1.3	K2	1
20	b	AI-4.2.1	K2	1

Número da questão (#)	Resposta correta	LO	Nível K	Pontos
21	d	AI-4.2.2	K3	2
22	b	AI-4.3.1	K2	1
23	a	AI-4.3.2	K2	1
24	a	AI-5.1.1	K2	1
25	c	AI-5.1.2	K2	1
26	d	AI-5.1.3	K2	1
27	b	AI-5.1.4	K2	1
28	c	AI-5.1.5	K3	2
29	b	AI-5.1.6	K2	1
30	b	AI-6.1.1	K2	1
31	a	AI-6.1.2	K2	1
32	a	AI-6.1.3	K2	1
33	c	AI-6.1.4	K2	1
34	b	AI-6.1.5	K3	2
35	b	AI-6.1.7	K2	1
36	c	AI-6.1.8	K2	1
37	c	AI-6.1.9	K2	1
38	d	AI-6.1.10	K2	1
39	b, d	AI-7.1.1	K2	1
40	b	AI-7.1.2	K2	1

Respostas

Legenda:

Q: questão | **RC:** resposta correta | **OA:** Objetivo de aprendizagem | **K:** nível cognitivo de conhecimento | **P:** pontuação da questão

Q	RC	Explicação / Fundamentação	OA	K	P
1	a	<p>a) Correto. Isso diferencia corretamente os sistemas baseados em IA dos sistemas convencionais. Os sistemas baseados em IA/ML aprendem padrões nos dados, e muitos podem se adaptar por meio do autoaprendizado, enquanto os sistemas convencionais utilizam lógica predefinida e produzem resultados previsíveis. Observação: isso não se aplica a sistemas especialistas baseados em regras.</p> <p>b) Incorreto. Embora os sistemas baseados em IA possam, às vezes, processar dados mais rapidamente, isso nem sempre ocorre, e sua vantagem reside mais na adaptabilidade e no tratamento da complexidade do que na velocidade.</p> <p>c) Incorreto. Isso inverte as características dos dois tipos de sistemas. Os sistemas baseados em IA são probabilísticos e têm menor explicabilidade, enquanto os sistemas convencionais são determinísticos e mais simples de interpretar.</p> <p>d) Incorreto. Os sistemas convencionais são mais adequados para tarefas críticas nas quais a capacidade de explicar os resultados é importante; os sistemas baseados em IA geralmente apresentam baixa transparência e explicabilidade e, portanto, são mais apropriados para uso em áreas não regulamentadas. Além disso, os sistemas baseados em IA costumam ser mais adequados para problemas mais complexos.</p>	IA-1.1.1	K2	1
2	c, e	<p>a) Incorreto. A IA estreita não é autodidática em todos os casos; ela é específica para determinadas tarefas. A IA geral não se limita a problemas especializados, e a super IA não se limita a tarefas predefinidas.</p> <p>b) Incorreto. A IA estreita não opera independentemente da intervenção humana, a IA geral não é exclusiva da robótica e a super IA não se limita a aprimorar a tomada de decisões humanas, mas, hipoteticamente, supera totalmente a inteligência humana.</p> <p>c) Correto. Isso diferencia com precisão os três tipos de IA destacando a natureza específica para tarefas da IA estreita, a versatilidade semelhante à humana da IA geral e a natureza hipotética e as capacidades superiores da super IA.</p>	IA-1.1.2	K2	1

Q	RC	Explicação / Fundamentação	OA	K	P
		<p>d) Incorreto. Embora a IA estreita seja corretamente identificada como específica para tarefas, a IA geral, se alcançada, teria muitas aplicações no mundo real. Além disso, não está claro que relação a super IA teria com modelos de IA generativa.</p> <p>e) Correto. Toda IA hoje é IA restrita. Não está claro quando a IA geral será alcançada. Uma vez que tenhamos a IA geral, dada a disponibilidade de conhecimento na internet, é quase certo que a super IA será alcançada.</p>			
3	a	<p>a) Correto. IA é o termo mais abrangente. Refere-se ao conceito geral de criar máquinas capazes de realizar tarefas que normalmente exigem inteligência humana. Isso inclui uma ampla gama de abordagens e técnicas, não apenas o machine learning. ML é um subconjunto da IA. É uma abordagem específica para alcançar a IA, na qual as máquinas recebem a capacidade de aprender a partir de dados sem serem explicitamente programadas. Em vez de escrever regras específicas para cada situação, os algoritmos de ML aprendem padrões e fazem previsões com base nos dados. DL é um subconjunto do machine learning. É um tipo especializado de machine learning que utiliza redes neurais artificiais com múltiplas camadas (daí o termo “profundo”).</p> <p>b) Incorreto. A IA e o ML já existiam como conceitos e campos de estudo muito antes de o aprendizado profundo se tornar proeminente. O aprendizado profundo é um avanço relativamente recente dentro dos campos mais amplos do machine learning e da IA.</p> <p>c) Incorreto. DL e ML não são intercambiáveis. DL é um tipo específico de ML. Além disso, a IA não representa uma “abordagem separada” — ML e DL são abordagens para implementar a IA.</p> <p>d) Incorreto. Embora seja verdade que a IA abrange o ML e o DL, “trabalhar em paralelo” não é uma forma válida de descrever a relação entre eles. O DL é um tipo de ML, não uma metodologia paralela no mesmo nível que possa ser executada em paralelo.</p>	IA-1.1.3	K2	1
4	b	<p>a) Incorreto. Descreve análise e compreensão, que não são capacidades da GenAI, e não se concentra no aspecto generativo da IA generativa.</p> <p>b) Correto. Isso descreve com precisão a IA generativa, destacando sua capacidade de criar conteúdos com base em padrões aprendidos nos dados de treinamento.</p> <p>c) Incorreto. A IA generativa concentra-se na criação de novos conteúdos, em vez de melhorar os conteúdos existentes como precursor de tarefas de IA mais tradicionais, tais como tarefas de classificação e previsão.</p>	IA-1.1.4	K2	1

Q	RC	Explicação / Fundamentação	OA	K	P
		d) Incorreto. A IA generativa não se limita a texto e imagens; ela tem aplicações na área da saúde, na descoberta de medicamentos, na simulação de dados e em outros campos.			
5	a	<p>a) Correto. Essa comparação destaca com precisão as vantagens das GPUs em relação às CPUs para tarefas de machine learning, devido às suas capacidades de processamento paralelo, enquanto as CPUs se destacam na computação de uso geral.</p> <p>b) Incorreto. Embora as CPUs tenham velocidades de clock mais rápidas, elas são menos eficientes do que as GPUs para tarefas de ML, pois carecem dos requisitos de processamento paralelo massivos necessários para tarefas de manipulação de dados, como a multiplicação de matrizes.</p> <p>c) Incorreto. Hardware específico para IA, como ASICs, é mais adequado para computação de ponta do que para o treinamento de modelos ML, o que normalmente é feito na nuvem.</p> <p>d) Incorreto. Os processadores neuromórficos são projetados para imitar a estrutura do cérebro e não dependem da arquitetura de von Neumann; portanto, essa afirmação é imprecisa.</p>	IA-1.1.5	K2	1
6	b	<p>Considerando as seguintes afirmações sobre o desenvolvimento e a hospedagem de modelos de IA:</p> <p>i. Ele reduz os custos de desenvolvimento ao utilizar recursos de nuvem pública, eliminando a necessidade de investimento em hardware local ⇒ Esta não é uma abordagem híbrida, pois se refere apenas ao desenvolvimento na nuvem.</p> <p>ii. Utiliza o desenvolvimento local de componentes de preparação de dados para dados confidenciais, a fim de aumentar a segurança, antes de migrar para a nuvem para o treinamento do sistema completo ⇒ Esta é <u>uma abordagem híbrida</u>, pois temos desenvolvimento local para preparação de dados e treinamento na nuvem.</p> <p>iii. Isso resulta em custos mais baixos porque laptops são usados para o desenvolvimento local e há baixos custos iniciais de hardware ao hospedar modelos de IA em nuvens públicas</p>	IA-1.1.6	K2	1

Q	RC	Explicação / Fundamentação	OA	K	P
		<p>⇒ Isso é <u>híbrido</u>, pois há desenvolvimento local em laptops e hospedagem em nuvens públicas.</p> <p>iv. Simplifica o desenvolvimento e a hospedagem ao padronizar processos em servidores locais, eliminando a necessidade de configurações complexas baseadas na nuvem</p> <p>⇒ Isso não é híbrido, pois tudo está em servidores locais.</p> <p>v. Isso garante a mais alta segurança ao hospedar modelos de IA em nuvens privadas, evitando assim os riscos associados a vulnerabilidades de hardware local</p> <p>⇒ Isso não é híbrido, pois tudo está em nuvens privadas.</p> <p>Portanto, a opção correta é b) ii e iii.ii</p>			
7	C	<p>Considerando cada um dos exemplos separadamente:</p> <p>A. Incorreto. A efetividade da intervenção humana na operação do sistema durante um comportamento perigoso da IA é avaliada pela taxa de sucesso de um operador remoto em forçar um drone a entrar no protocolo de pouso seguro quando seu sistema de navegação de IA exibe um comportamento perigoso. Essa medição avalia a efetividade da intervenção humana na operação do sistema durante um comportamento perigoso da IA alinhando-se à definição de intervenibilidade: a capacidade de permitir intervenção externa em processos automatizados. Isso corresponde à intervenibilidade (4).</p> <p>B. Incorreto. O tempo médio necessário para anular com sucesso a decisão automatizada de um sistema de gerenciamento de fraudes de bloquear a transação de um cliente. Essa medição diz respeito à rapidez com que um usuário pode anular a decisão de um sistema automatizado e ao grau em que um usuário pode controlar ou influenciar as ações do sistema. Esse é um indicador direto da controlabilidade do usuário (2).</p> <p>C. Correto. O F1-score de um modelo de detecção de objetos em um carro autônomo sob chuva forte. O F1-score em condições adversas (chuva forte) testa a performance do modelo em cenários desafiadores, o que é uma medição da robustez da IA (1).</p> <p>D. Incorreto. O tempo necessário para que um mecanismo de recomendação de comércio eletrônico atualize suas sugestões para refletir uma nova tendência de moda que surge rapidamente. A velocidade com que um sistema adapta suas recomendações às novas</p>	AI-2.1.1	K2	1

Q	RC	Explicação / Fundamentação	OA	K	P
		tendências reflete sua capacidade de adaptar sua funcionalidade a requisitos em constante mudança, o que é a adaptabilidade funcional (3). Nesse caso, a combinação correta é: 1C – 2B – 3D – 4A, o que torna a opção c) correta.			
8	b	<p>a) Incorreto. O problema real é o oposto: os requisitos são geralmente muito vagos e, muitas vezes, são fornecidos apenas implicitamente pelos dados, levando a uma baixa rastreabilidade.</p> <p>b) Correto. Essa imprevisibilidade é um desafio central de segurança ao implantar IA em sistemas relacionados à segurança, pois complica a verificação, a validação e a garantia contínua de operação segura.</p> <p>c) Incorreto. O problema é que os sistemas de autoaprendizagem não param de se adaptar após a implantação e, assim, se afastam do comportamento original testado.</p> <p>d) Incorreto. As normas de maturidade relacionadas à segurança atualmente carecem de disposições para a IA, e algumas restringem explicitamente seu uso.</p>	IA-2.1.2	K2	1
9	c	<p>a) Incorreto. Isso se refere à capacidade de intervenção, conforme definido na ISO 25059, que descreve a capacidade do usuário de controlar o robô de patrulha autônomo quando percebe que ele pode colidir com uma escultura. Também fornece um prazo específico e de medição para a intervenção.</p> <p>b) Incorreto. Isso se refere à correção funcional, definida na ISO 25059. Ela descreve como o sistema se adapta às mudanças de umidade para manter o ambiente desejado. Ela fornece umidade específica e de medição e um prazo para o sistema de controle reagir.</p> <p>c) Correto. É a opção MENOS provável porque se concentra em algumas das subcaracterísticas da usabilidade, como a aprendibilidade e a operabilidade, que são características genéricas de qualidade aplicáveis à maioria dos sistemas e não estão diretamente associadas às características específicas da IA na ISO 25059 (ou seja, controlabilidade do usuário e transparência, que são subcaracterísticas da usabilidade para sistemas baseados em IA). O critério de aceitação também é mais subjetivo do que as outras opções e, portanto, mais difícil de testar.</p> <p>d) Incorreto. Isso se refere à transparência, que é definida na ISO 25059. Ela descreve o fornecimento de informações adicionais pelo sistema para explicar sua tomada de decisão.</p>	IA-2.2.1	K2	1

Q	RC	Explicação / Fundamentação	OA	K	P
10	a	<p>Considerando as descrições dos sistemas de exemplo:</p> <ol style="list-style-type: none"> 1. Aprendizado por reforço - O valor gasto pode ser considerado a função de recompensa para este sistema, com o sistema alterando seu comportamento para aumentar o valor gasto. (B) 2. Classificação — O aplicativo utiliza texto no que pode ser considerado um idioma de origem e uma tradução “correta” correspondente a essa origem, empregando uma forma de aprendizado supervisionado sem nenhuma função de recompensa explícita mencionada. A classificação utiliza dados de treinamento paralelos — pares de frases correspondentes em dois idiomas (por exemplo, “Hello” em inglês e “Bonjour” em francês) — onde cada par possui um rótulo que vincula o texto de origem ao texto de destino. O modelo aprende mapeamentos por meio de treinamento supervisionado, codificando características do texto de entrada e prevendo a saída de tradução correta, minimizando erros em muitos desses pares para generalizar para novas frases. (C) 3. A regressão é usada neste cenário para prever um resultado contínuo (neste caso, o tempo até a falha do equipamento) com base em um conjunto de variáveis de entrada (dados de sensores e registros históricos de manutenção). Ao analisar a relação entre essas variáveis, o modelo ML pode identificar padrões e tendências que indicam quando o equipamento está em risco de falha. (D) 4. Agrupamento - Ao analisar as interações dos usuários (por exemplo, curtidas, comentários, conteúdo compartilhado) e os interesses declarados, a plataforma de rede social pode identificar padrões e semelhanças entre os usuários da Calibera. Esses padrões podem então ser usados para agrupar usuários em comunidades ou “clusters” que compartilham interesses e comportamentos comuns. (A) <p>Portanto, 1B – 2C – 3D – 4A está correto e, assim, a opção a) é a opção correta.</p>	AI-3.1.1	K2	1
11	d	<ol style="list-style-type: none"> 1. O desempenho do modelo é testado usando dados de validação Isso faz parte da atividade “Avaliar o modelo”. (D) 2. A origem dos dados de teste utilizados para testar o modelo é identificada Isso faz parte da atividade “Preparar e testar dados de teste”. (B) 	AI-3.1.2	K2	1

Q	RC	Explicação / Fundamentação	OA	K	P
		<p>3. Os dados de teste são utilizados para determinar se os critérios de performance acordados foram atendidos Isso faz parte da atividade “Teste do modelo”. (C)</p> <p>4. O modelo é testado na plataforma de destino Isso faz parte da atividade “Implantar o modelo”. (A)</p> <p>Portanto, a opção correta é: 1D – 2B – 3C – 4A, e assim d) CORRETO.</p>			
12	d	<p>a) Incorreto. A abordagem RAG não adiciona novas camadas à rede neural para armazenar documentação; em vez disso, ela recupera dados externos relevantes no momento da inferência e complementa a entrada do modelo com essas informações.</p> <p>b) Incorreto. Embora o ajuste fino com dados de alta qualidade possa reduzir o viés, ele não garante a prevenção de resultados injustos, pois o viés pode persistir ou até mesmo ser introduzido durante o processo de ajuste fino.</p> <p>c) Incorreto. O ajuste fino pode ser realizado em todas as camadas ou apenas em um subconjunto. Frequentemente, apenas algumas camadas são atualizadas, enquanto outras são mantidas congeladas, dependendo da tarefa e dos dados disponíveis.</p> <p>d) Correto. O RAG depende da curadoria e indexação de dados externos relevantes antes do uso, mas não requer a modificação da arquitetura ou dos parâmetros do próprio modelo pré-treinado; em vez disso, ele complementa as entradas do modelo com informações recuperadas em tempo de execução.</p>	AI-3.1.4	K2	1
13	c	<p>a) Incorreto. Esta afirmação destaca uma etapa fundamental na preparação de dados: coletar e consolidar dados de diferentes fontes antes de iniciar qualquer processamento ou análise. No entanto, a preparação de dados normalmente também envolve limpar, transformar e organizar os dados, além de coletar dados brutos.</p> <p>b) Incorreto. Esta afirmação é imprecisa porque a engenharia de características é geralmente realizada antes (ou durante) o treinamento do modelo ML, e não depois. O objetivo da engenharia de características é criar ou modificar características para melhorar a performance do modelo ML durante a fase de treinamento.</p> <p>c) Correto. Isso identifica corretamente duas técnicas comuns de pré-processamento de dados: aumento (aumentar os dados criando versões modificadas) e amostragem (reduzir os dados selecionando subconjuntos).</p>	AI-3.2.1	K2	1

Q	RC	Explicação / Fundamentação	OA	K	P
		d) Incorreto. Esta afirmação captura parcialmente o objetivo da EDA, que é compreender as características dos dados e detectar problemas por meio de visualização e estatísticas resumidas. No entanto, a EDA não é um “teste exploratório”, mas sim um processo analítico que orienta as etapas subsequentes de preparação dos dados de teste.			
14	b	<p>a) Incorreto. O conjunto de dados de treinamento é usado principalmente para ajustar os parâmetros do modelo, não para otimizar os hiperparâmetros. O conjunto de dados de validação é normalmente utilizado para ajustar os hiperparâmetros, e o conjunto de dados de teste nunca é usado para gerar dados de treinamento.</p> <p>b) Correto. O conjunto de dados de treinamento é usado para ajustar ou criar o modelo, o conjunto de dados de validação é usado para ajustar os hiperparâmetros do modelo e evitar o overfitting, e o conjunto de dados de teste é reservado para avaliar o desempenho do modelo em dados não vistos. Isso descreve com precisão as funções distintas e sequenciais de cada conjunto de dados no fluxo de trabalho de ML.</p> <p>c) Incorreto. O conjunto de dados de treinamento não é usado para a avaliação final do modelo — essa é a função do conjunto de dados de teste. Além disso, o conjunto de dados de teste não é usado para ajustar hiperparâmetros, pois isso teria o risco de causar overfitting ao conjunto de dados de teste.</p> <p>d) Incorreto. O papel principal do conjunto de dados de treinamento não é garantir a generalização, mas ajustar o modelo. O conjunto de dados de validação não é usado para implantação, e o conjunto de dados de teste não é usado para avaliação inicial, mas para avaliação final após o desenvolvimento do modelo</p>	AI-3.2.3	K2	1
15	c	<p>a) Incorreto. Veja a opção c para a fórmula e o cálculo corretos.</p> <p>b) Incorreto. Veja a opção c para a fórmula e o cálculo corretos.</p> <p>c) Correto. A fórmula para Precisão = $TP/(TP+FP) * 100 = 78/(78+22) = 78/100 * 100$</p> <p>d) Incorreto. Veja a opção c para a fórmula e o cálculo corretos.</p>	AI-3.3.1	K3	2
16	a	<p>a) Correto. Este é o próximo passo no ciclo de treinamento de ML. A perda é realimentada através da rede para ajustar os valores dos pesos e dos vieses.</p> <p>b) Isso Incorreto. O treinamento passa para o próximo lote de dados ou conclui a época. Ele não repete o processamento dos mesmos dados apenas para confirmar o valor da perda.</p>	AI-3.4.1	K2	1

Q	RC	Explicação / Fundamentação	OA	K	P
		<p>c) Incorreto. As funções de ativação são escolhidas durante o projeto do modelo e geralmente não são alteradas durante uma execução de treinamento.</p> <p>d) Incorreto. A reinicialização dos pesos ocorre no início do treinamento (inicialização), não após o cálculo do valor de perda para um lote de dados.</p>			
17	a	<p>Considerando o exemplo fornecido de sistemas baseados em IA:</p> <ul style="list-style-type: none"> i. Um sistema que aprende com dados em tempo real para melhorar suas previsões de falhas e atualiza automaticamente os cronogramas de manutenção. Trata-se de uma forma de sistema adaptativo baseado em IA que altera os cronogramas com base em dados em tempo real. ii. Um filtro de spam em um aplicativo de e-mail, que identifica spam com base em regras predefinidas. Trata-se de um sistema baseado em IA fixo, que gera resultados do teste previsíveis, pois se baseia no cumprimento de regras predefinidas de identificação de spam que não serão alteradas até que o modelo baseado em regras seja reconstruído. iii. Um mecanismo de recomendação em um serviço de streaming que atualiza suas sugestões com base nas mudanças nos hábitos e preferências de visualização do usuário. Trata-se de um sistema adaptativo que se adapta com base nos hábitos e preferências de visualização do usuário. iv. Um assistente pessoal que aprende com seu usuário. Trata-se de um sistema adaptativo baseado em IA, pois adapta seus parâmetros com base nas interações dos usuários com o sistema. v. Um sistema baseado em regras para diagnóstico médico. Trata-se de uma forma de sistema baseado em IA fechado, que não alterará as regras do domínio até que o modelo baseado em regras seja reconstruído. <p>Assim, o filtro de spam e os sistemas de diagnóstico médico seriam mais simples de testar, pois ambos são formas de sistemas fechados e geram resultados do teste previsíveis.</p> <p>Portanto, a opção a) está correta</p>	IA-4.1.1	K2	1
18	b	<p>a) Incorreto. Embora os sistemas baseados em IA possam ser grandes e complexos, a justificativa para o uso de uma abordagem estatística é motivada principalmente por sua natureza não determinística, e não pela impraticabilidade da automação ou pelo tamanho.</p>	IA-4.1.2	K2	1

Q	RC	Explicação / Fundamentação	OA	K	P
		<p>b) Correto. Os sistemas baseados em IA são não determinísticos e requerem conjuntos de dados de teste extensos e representativos para alcançar significância estatística, especialmente na avaliação estatística da correção funcional.</p> <p>c) Incorreto. Esta opção deturpa o conceito. Um único caso de teste não é suficiente para avaliar a qualidade do sistema baseado em IA. É necessária uma avaliação estatística sobre muitas previsões.</p> <p>d) Incorreto. Isso contradiz as melhores práticas. Um conjunto de dados de teste separado (do treinamento e da validação) é essencial, não opcional, e faz parte do rigor estatístico exigido.</p>			
19	b	<p>a) Incorreto. Definir uma semente é um detalhe de implementação independente da qualidade ou da completude das especificações do sistema.</p> <p>b) Correto. A definição de uma “semente” está vinculada a uma execução de teste específica e não resolve a natureza probabilística fundamental do modelo quando ele opera em um ambiente real.</p> <p>c) Incorreto. A escolha de uma semente é uma etapa simples de programação e não envolve especialistas na área.</p> <p>d) Incorreto. Definir uma semente não torna o comportamento subjetivo. Para uma determinada rodada de teste, isso deve tornar o comportamento objetivo e repetível.</p>	AI-4.1.3	K2	1
20	b	<p>a) Incorreto. Modelos de IA generativa não produzem resultados determinísticos; portanto, a correspondência exata com resultados esperados predefinidos não é uma abordagem adequada para este teste.</p> <p>b) Correto. Devido à variabilidade e complexidade dos resultados da IA gerativa, os testes se concentram na coerência, conformidade com regras e plausibilidade, em vez de uma correspondência e com resultados esperados fixos. Entradas diversas, prompts opcionais e parâmetros influenciam os resultados dos testes.</p> <p>c) Incorreto. Embora os modelos de IA generativa sejam probabilísticos, os testes (por exemplo, testes exploratórios, testes metamórficos e testes contraditórios) ainda podem ser utilizados.</p> <p>d) Incorreto. A revisão manual é possível, mas métodos automatizados, incluindo outras ferramentas de GenAI ou sistemas de reconhecimento de imagem, também podem avaliar efetivamente o conteúdo gerado. Portanto, afirmar que os testes automatizados “não se aplicam” são imprecisos.</p>	IA-4.2.1	K2	1

Q	RC	Explicação / Fundamentação	OA	K	P
21	d	<p>a) Incorreto. O red teaming é normalmente realizado antes da implantação.</p> <p>b) Isso Incorreto. A questão não fornece nenhuma orientação de que a segurança seja mais ou menos importante do que o teste de viés.</p> <p>c) Incorreto. O red teaming é realizado de forma proativa antes da implantação.</p> <p>d) Correto. O red teaming deve ser realizado antes da implantação, não depois, e vários tipos de vulnerabilidades (segurança e viés) devem ser testados em conjunto.</p>	AI-4.2.2	K3	2
22	b	<p>a) Incorreto. Embora o teste de sistema possa ter detectado esse defeito, o teste de dados de entrada é o nível de teste mais eficaz para detectá-lo, pois ele teria sido identificado em uma fase anterior.</p> <p>b) Correto. O teste de dados de entrada concentra-se na qualidade dos dados e na representatividade dos dados. Parece que áreas no Reino Unido com altitude superior a 1.250 metros não foram adequadamente representadas nos dados de treinamento.</p> <p>c) Incorreto. O teste de integração de componentes verifica se há defeitos nas interfaces e nas interações entre componentes e não se concentra em valores de dados específicos.</p> <p>d) Incorreto. O teste do modelo ML pode ter identificado esse defeito, mas o teste de dados de entrada seria o nível de teste mais eficaz para detectá-lo, pois ele teria sido detectado mais cedo.</p>	AI-4.3.1	K2	1
23	a	<p>a) Correto. Segurança e usabilidade são características genéricas de qualidade e podem se aplicar a qualquer sistema. O viés de dados e a performance do modelo são riscos potenciais específicos dos sistemas de ML.</p> <p>b) Incorreto. Tanto o viés de dados quanto o viés algorítmico são riscos associados explicitamente a um sistema de ML e, portanto, não se aplicam a sistemas convencionais.</p> <p>c) Incorreto. O gerenciamento de risco tanto para sistemas não baseados em IA quanto para sistemas de IA (incluindo sistemas de ML com autoaprendizagem) deve ser de natureza dinâmica.</p> <p>d) Incorreto. A correção funcional pode ser o principal fator de risco para sistemas convencionais e para sistemas de ML, mas isso depende do contexto.</p>	IA-4.3.2	K2	1
24	a	<p>a) Correto. O cenário descreve a necessidade de verificar a origem dos dados e determinar se eles não foram adulterados. Isso se refere ao teste de proveniência de dados.</p>	AI-5.1.1	K2	1

Q	RC	Explicação / Fundamentação	OA	K	P
		<p>b) Incorreto. Embora a equipe provavelmente realize um teste de representatividade dos dados em um novo conjunto de dados, essa atividade aborda se as características dos dados correspondem às do mundo real, e não se sua origem documentada é precisa ou se são dados brutos válidos.</p> <p>c) Incorreto. O teste de características avalia o poder preditivo das características, o que é uma questão diferente da verificação da fonte e da integridade do próprio conjunto de dados.</p> <p>d) Incorreto. O teste de restrições de conjuntos de dados verifica a consistência interna do conjunto de dados (por exemplo, intervalos, tipos), mas não pode verificar de onde os dados vieram ou se foram alterados ilegalmente.</p>			
25	c	<p>a) Incorreto. Essa abordagem concentra-se na lógica do modelo, não nas características dos dados de treinamento. Ela não revela diretamente os padrões de viés presentes nos dados.</p> <p>b) Incorreto. Essa abordagem examina os resultados do modelo, em vez dos próprios dados de treinamento. É útil para identificar viés nas previsões, mas não para a detecção inicial de viés nos dados.</p> <p>c) Correto. Essa abordagem poderia ajudar a identificar onde o viés poderia ser introduzido, mas depende de verificações do processo, em vez de evidências reais extraídas dos dados.</p> <p>d) Incorreto. Essa abordagem avalia os resultados ou previsões sob mudanças hipotéticas, visando o viés de resultado em vez de avaliar diretamente o conjunto de dados de treinamento.</p>	AI-5.1.2	K2	1
26	d	<p>a) Incorreto. Ambos os tipos de pipeline se beneficiariam de uma abordagem totalmente em camadas. Um pipeline operacional exigiria testes extensivos de ponta-a-ponta do sistema, não apenas a validação de scripts individuais.</p> <p>b) Incorreto. Ambos os tipos de pipeline utilizariam uma variedade de testes. Limitar um a apenas uma abordagem de teste no nível do sistema e o outro a apenas uma abordagem de teste no nível de componentes e integração não segue uma abordagem em camadas.</p> <p>c) Incorreto. O gerenciamento de configuração verifica se as versões corretas são usadas “em treinamento, testes e produção”, o que implica que é importante que ambos os tipos de pipelines ofereçam consistência e reprodutibilidade, não apenas os operacionais.</p> <p>d) Correto. O objetivo do pipeline determina a estratégia de teste. Os pipelines de treinamento priorizam a geração de dados de alta qualidade, enquanto os pipelines operacionais em</p>	AI-5.1.3	K2	1

Q	RC	Explicação / Fundamentação	OA	K	P
		produção se concentram em aspectos não funcionais, como eficiência de performance, escalabilidade e robustez da IA.			
27	b	<p>a) Incorreto. Um conjunto de dados de referência não precisa ser universalmente aplicável nem derivado exclusivamente de benchmarks do setor. Ele é normalmente adaptado para corresponder às características operacionais e contextuais da população-alvo do sistema de IA.</p> <p>b) Correto. O objetivo principal do conjunto de dados de referência é fornecer uma linha de base estatística, permitindo que os profissionais comparem objetivamente as distribuições, as correlações de características e a cobertura dos dados de treinamento com o que é esperado em ambientes operacionais do mundo real.</p> <p>c) Incorreto. A amostragem estratificada é normalmente aplicada ao conjunto de dados de referência para criar uma linha de base abrangente, em vez de diretamente aos próprios dados de treinamento. O conjunto de dados de referência visa garantir que todos os subgrupos relevantes estejam representados, servindo como um padrão para avaliar a representatividade dos outros conjuntos de dados.</p> <p>d) Incorreto. O conjunto de dados de referência não se destina a ser a principal fonte para o teste final do modelo ML ou testes com alta independência. Ele existe para avaliar a representatividade dos dados antes do treinamento do modelo.</p>	AI-5.1.4	K2	1
28	c	<p>a) Incorreto. Uma restrição de intervalo apenas valida se os valores de um único atributo estão dentro dos limites especificados, mas não verifica a relação matemática entre pagamento_mensal e valor_do_empréstimo.</p> <p>b) Incorreto. Uma restrição de contagem verifica a quantidade de valores não nulos, não a correção matemática de campos calculados.</p> <p>c) Correto. Este cenário requer a validação de uma relação matemática entre dois atributos (pagamento_mensal e valor_do_empréstimo). A restrição de correlação foi projetada especificamente para verificar se os valores de um atributo se correlacionam com os valores de outro atributo de acordo com uma regra definida — neste caso, que pagamento_mensal seja igual a valor_do_empréstimo/324.</p> <p>d) Incorreto. Uma restrição de duplicidade identifica valores idênticos, mas ter pagamentos mensais duplicados pode ser legítimo (diferentes candidatos podem ter o mesmo valor de pagamento).</p>	AI-5.1.5	K3	2

Q	RC	Explicação / Fundamentação	OA	K	P
29	b	<p>a) Incorreto. Anotações múltiplas normalmente não são automatizadas. A anotação múltipla geralmente depende de anotadores humanos e não garante consistência; em vez disso, ela destaca inconsistências.</p> <p>b) Correto. A anotação múltipla envolve pontos de dados sendo rotulados de forma independente por vários anotadores. A comparação desses rótulos leva à descoberta e de divergências entre os anotadores, destacando possíveis defeitos.</p> <p>c) Incorreto. Comparar distribuições de rótulos faz parte da análise de distribuição de dados, não das anotações múltiplas.</p> <p>d) Incorreto. Sinalizar pontos de dados com alta perda é função da análise de perda do modelo, não da anotação múltipla.</p>	AI-5.1.7	K2	1
30	b	<p>Considerando cada um dos riscos separadamente:</p> <p>A. O modelo ML pode apresentar desempenho diferente para diferentes grupos demográficos. Isso se encaixa melhor com o Teste de Viés, que examina explicitamente a equidade entre diferentes populações. (2)</p> <p>B. Entradas ligeiramente modificadas no modelo ML podem causar respostas bastante diferentes e inesperadas. Isso combina corretamente com o teste contraditório, que testa deliberadamente a capacidade de um modelo ML de lidar com pequenas perturbações nas entradas. (3)</p> <p>C. As previsões feitas pelo modelo ML podem ser imprecisas em alguns casos. Isso é mais bem abordado pelo Teste Funcional do ML, que avalia diretamente se o modelo ML produz resultados precisos. (1)</p> <p>D. A precisão do modelo ML pode ter diminuído significativamente desde que foi implantado. Isso se encaixa adequadamente com o Teste de Desvio, que monitora as mudanças de performance ao longo do tempo em produção. (4)</p> <p>Assim, a combinação correta entre riscos e abordagens de teste é: 1C – 2A – 3B – 4D, e, portanto, b) é a opção correta.</p>	AI-6.1.1	K2	1
31	a	<p>a) Correto. Isso faz parte dos requisitos/documentação não funcionais.</p> <p>b) Incorreto. Não está dentro do escopo da documentação do modelo.</p> <p>c) Incorreto. A documentação do modelo deve conter a fonte dos dados de treinamento.</p>	AI-6.1.2	K2	1

Q	RC	Explicação / Fundamentação	OA	K	P
		d) Incorreto. A documentação das alterações feitas pelo sistema de autoaprendizagem só poderia ser feita pelo próprio sistema no momento da atualização.			
32	a	<p>a) Correto. Quando mais testes são realizados para a mesma precisão da medição (83%), a margem de erro normalmente diminui se o nível de confiança permanecer o mesmo. Isso ocorre porque uma amostra maior pode reduzir a margem de erro e/ou aumentar nossa confiança estatística no valor medido. Se o modelo ML anteriormente alcançou 83% de precisão com uma margem de erro de $\pm 4\%$ em um nível de confiança de 94%, e testes adicionais foram realizados mantendo a medição de precisão de 83% e mantendo o nível de confiança em 94%, isso resultaria em uma margem de erro menor (por exemplo, $\pm 2\%$). Isso indica que podemos ter mais certeza de que a precisão real está de fato em torno de 83%.</p> <p>b) Incorreto. Quando mais testes são realizados, a margem de erro normalmente diminui e o nível de confiança normalmente aumenta, em vez de diminuir, supondo que a precisão medida permaneça a mesma. Passar de 94% para 92% de confiança indicaria que menos testes foram realizados ou que os resultados dos testes foram mais variáveis, o que contradiz o cenário em que testes adicionais foram realizados.</p> <p>c) Incorreto. Se testes adicionais fossem realizados e a precisão permanecesse em 83%, a margem de erro normalmente diminuiria e não aumentaria, se o nível de confiança fosse mantido em 94%. O aumento da margem de erro de $\pm 6\%$ tornam essa opção menos provável do que a opção em que ela diminui (a).</p> <p>d) Isso Incorreto. O cenário indica que a precisão do modelo ML nos testes adicionais foi medida em 83%, e não em 85%. Um aumento na porcentagem de precisão indicaria que o modelo ML teve um desempenho melhor nos testes adicionais, o que contradiz a informação fornecida de que o modelo ML “forneceu previsões corretas menos vezes do que o esperado”, mantendo a precisão medida de 83%.</p>	AI-6.1.3	K2	1
33	c	<p>a) Incorreto. Isso sugere erroneamente que o conhecimento interno do modelo ML é irrelevante, enquanto tal conhecimento pode aprimorar o processo de teste ao criar exemplos contraditórios mais direcionados.</p> <p>b) Incorreto. Sugere incorretamente que os métodos manuais são a única abordagem, ignorando as técnicas automatizadas, que também são cruciais nos testes contraditórios.</p>	AI-6.1.4	K2	1

Q	RC	Explicação / Fundamentação	OA	K	P
		<p>c) Correto. No teste contraditório, os exemplos contraditórios são frequentemente criados para identificar vulnerabilidades por meio da perturbação de entradas válidas.</p> <p>d) Incorreto. Isso ignora o objetivo dos testes contraditórios, que utilizam deliberadamente valores de entrada atualizados (ou seja, testes) para criar exemplos contraditórios.</p>			
34	b	<p>Considerando os seguintes casos de teste de acompanhamento: O caso de teste T1 difere do caso de teste original pela alteração nos requisitos para uma câmera 3D; agora é mais específico. Uma câmera 3D deve ser incluída. Portanto, isso significa que os resultados esperados do acompanhamento podem incluir, no máximo, os resultados do teste original (os telefones recomendados anteriormente, mas com uma câmera 3D). O caso de teste T2 também difere do caso de teste original devido à alteração nos requisitos para uma câmera 3D; ele também é mais específico. Nenhuma câmera 3D deve ser incluída. Portanto, isso significa que os resultados esperados do acompanhamento podem incluir, no máximo, os resultados do teste original (os telefones recomendados anteriormente, mas sem câmera 3D). Como T1 lista telefones <u>com</u> câmera 3D, os telefones restantes do caso de teste de origem devem ser aqueles sem câmera 3D e, portanto, devem estar em T2. Portanto, T1 e T2 combinados devem conter todas as câmeras do caso de teste de origem, mas sem sobreposição entre os dois.</p> <p>a) Incorreto. A câmera SnapHappy M3 está faltando nos resultados combinados de T1 e T2 b) Correto. Não há sobreposição entre as saídas de T1 e T2, e nenhuma câmera está faltando. c) Incorreto. As câmeras SnapHappy estão listadas em ambos os casos de teste. d) Incorreto. A saída dos dois casos de teste é idêntica, apesar dos requisitos diferentes para a câmera 3D.</p>	AI-6.1.5	K3	2
35	b	<p>a) Incorreto. Embora o teste dinâmico seja apropriado quando a verdade de referência está disponível, ele não analisa as propriedades estatísticas dos dados de entrada. b) Correto. Como a verdade de referência não está disponível, o teste de desvio estático, que não a requer, é a única opção viável. c) Incorreto. A organização “não possui nenhum mecanismo para rastrear se um cliente realmente sai”. Portanto, não há resultados reais para comparação, tornando impossível a realização de testes dinâmicos.</p>	AI-6.1.7	K2	1

Q	RC	Explicação / Fundamentação	OA	K	P
		d) Incorreto. O teste estático analisa as distribuições de dados, enquanto a comparação de métricas de desempenho com a verdade de referência é o mecanismo do teste dinâmico.			
36	c	<p>a) Incorreto. O modelo ML apresenta boa performance nos dados de validação, portanto, é improvável que se trate de um caso de underfitting.</p> <p>b) Incorreto. O desvio de conceito refere-se a mudanças que ocorrem após o treinamento do modelo ML e as etapas de validação.</p> <p>c) Correto. O baixo desempenho nos dados de teste e o bom desempenho nos dados de validação sugerem overfitting.</p> <p>d) Incorreto. Os critérios de aceite devem ser consistentes com diferentes conjuntos de dados; portanto, é improvável que critérios de aceite baixos levem a uma diferença entre os resultados do teste com dados de validação e dados de teste independentes.</p>	AI-6.1.8	K2	1
37	c	<p>a) Isso Incorreto. De acordo com o syllabus, “o teste A/B não gera casos de teste e não oferece orientações sobre como os testes devem ser elaborados, embora muitas vezes sejam utilizados dados operacionais nos testes”. O teste A/B compara as respostas de duas variantes, em vez de gerar casos de teste.</p> <p>b) Incorreto. O teste A/B não se concentra nas interações entre componentes dentro de um sistema. Ele compara duas versões diferentes de um sistema, não componentes dentro de um único sistema.</p> <p>c) Correto. Conforme indicado no syllabus, “Sempre que o sistema é atualizado, o teste A/B é usado para verificar se a variante atualizada tem uma performance igual ou superior à da variante anterior.” Isso descreve com precisão como o teste A/B é usado no contexto de sistemas de ML.</p> <p>d) Incorreto. O teste A/B não analisa a estrutura interna do algoritmo. Trata-se de uma “abordagem de teste estatístico que normalmente requer a comparação dos resultados de várias rodadas de teste para determinar a diferença entre os programas”. Ele se concentra em comparar os resultados de duas variantes, e não em examinar suas estruturas internas.</p>	AI-6.1.9	K2	1
38	d	a) Incorreto. Variar os hiperparâmetros é um ajuste menor no mesmo modelo ML. Isso não altera fundamentalmente o modelo. Um pseudo-oráculo deveria, idealmente, ser significativamente diferente para detectar defeitos de forma eficaz. Esta opção é muito semelhante ao SUT.	AI-6.1.10	K2	1

Q	RC	Explicação / Fundamentação	OA	K	P
		<p>b) Incorreto. O ajuste fino é uma modificação do mesmo modelo ML, normalmente envolvendo treinamento adicional em um conjunto de dados específico. Não é uma mudança substancial o suficiente para criar um pseudo-oráculo verdadeiramente independente. Ele ainda depende do mesmo modelo e framework principais, aumentando o risco de defeitos compartilhados.</p> <p>c) Incorreto. A geração aumentada por recuperação (RAG) aprimora um modelo de linguagem ao integrá-lo a um mecanismo de recuperação. Embora a RAG acrescente complexidade, ela ainda se baseia no modelo ML central que está sendo testado. A arquitetura fundamental e o processo de treinamento do modelo base serão os mesmos. Embora a RAG introduza uma diferença, ela ainda é um aumento do modelo original, e não uma alternativa independente.</p> <p>d) Correto. Usar um framework de desenvolvimento de ML diferente significa usar bibliotecas diferentes, algoritmos subjacentes ou implementações de algoritmos potencialmente diferentes e um ambiente de desenvolvimento de ML diferente. Essa opção maximiza a independência do pseudo-oráculo em relação ao SUT, reduzindo o risco de defeitos compartilhados e aumentando a efetividade dos testes back-to-back.</p>			
39	b, d	<p>a) Incorreto. Isso descreve um risco de baixa eficiência de performance. A mitigação correta é o teste de performance (eficiência), que é distinto do teste funcional do ML (que avalia a correção funcional).</p> <p>b) Correto. Isso descreve um possível defeito na biblioteca utilizada. O teste de performance funcional do ML pode avaliar o comportamento do modelo e expor anomalias decorrentes do uso de uma nova biblioteca que esteja com defeito e causando uma alteração nos resultados dos testes.</p> <p>c) Incorreto. Isso descreve a necessidade de mitigar o risco de uma instalação defeituosa do framework de ML. A mitigação apropriada para isso é o teste de fumaça, não o teste de performance funcional completo do ML.</p> <p>d) Correto. Isso descreve o risco de má interpretação dos resultados dos testes devido à natureza estocástica do processo de aprendizado. O teste de performance funcional do ML, utilizando múltiplas rodadas de teste e análise estatística, é a medida de mitigação para isso.</p> <p>e) Incorreto. Isso descreve a seleção de um algoritmo subótimo. A mitigação apropriada é uma revisão da adequação do algoritmo ou testes A/B, e não testes de performance funcional do ML de um único algoritmo que ainda não foi selecionado.</p>	AI-7.1.1	K2	1

Q	RC	Explicação / Fundamentação	OA	K	P
40	b	<p>a) Isso não está correto: inverte os papéis dos dois tipos de teste. O teste canário aplica diretamente o novo modelo ML a um pequeno grupo de usuários reais, enquanto o shadow testing processa o tráfego ao vivo em segundo plano, sem nunca afetar as respostas dos usuários.</p> <p>b) Isso está correto: o shadow testing oferece uma maneira livre de riscos de verificar como um novo modelo ML se comporta com dados de produção, enquanto o teste canary expõe deliberadamente um pequeno subconjunto de usuários ao novo modelo para observar seu desempenho e impacto no mundo real.</p> <p>c) Isso não está correto: Ambos os tipos de teste são usados para validar o desempenho e a correção funcional de um modelo no tráfego ativo. A principal diferença é o perfil de risco, não se um é para testes de performance e o outro para teste de integração de componentes.</p> <p>d) Isso não está correto: isso representa erroneamente o teste canário como uma atividade offline. Tanto o teste canário quanto o shadow testing são métodos online que utilizam dados reais de usuários. A principal distinção é se a resposta do novo modelo ML é realmente enviada ao usuário ou se é apenas registrada para análise posterior.</p>	AI-7.1.2	K2	1

Apêndice: Respostas a perguntas adicionais

Chave de respostas

Número da questão (#)	Resposta correta	LO	Nível K	Pontos
A1	Novo tipo de pergunta	AI-1.1.2	K2	1
A2	a	AI-1.1.7	K2	1
A3	c	AI-1.1.8	K2	1
A4	Novo tipo de pergunta	AI-3.1.1	K2	1
A5	Novo tipo de pergunta	AI-3.1.2	K2	1
A6	c	AI-3.4.3	K2	1

Respostas

Legenda:

Q: questão | **RC:** resposta correta | **OA:** Objetivo de aprendizagem | **K:** nível cognitivo de conhecimento | **P:** pontuação da questão

Q	RC	Explicação / Fundamentação	OA	K	P
A1		<div style="border: 1px solid #ccc; padding: 10px; margin-bottom: 10px;"> <p>AI Estreita</p> <div style="display: flex; justify-content: space-around;"> <div style="border: 1px solid #ccc; padding: 5px; background-color: #e6f2e6; width: 45%;">Um sistema que examina imagens radiológicas para detectar os sinais específicos de tumores cancerígenos.</div> <div style="border: 1px solid #ccc; padding: 5px; background-color: #ffe0b2; width: 45%;">Um modelo de tradução que pode converter texto escrito do francês para o espanhol.</div> </div> </div> <div style="border: 1px solid #ccc; padding: 10px; margin-bottom: 10px;"> <p>AI Geral</p> <div style="display: flex; justify-content: space-around;"> <div style="border: 1px solid #ccc; padding: 5px; background-color: #fff9c4; width: 45%;">Um sistema que gerencia agendas diárias complexas, aprende novas receitas a partir de um vídeo e mantém conversas sobre romances que acabou de ler.</div> <div style="border: 1px solid #ccc; padding: 5px; background-color: #e0e0e0; width: 45%;">Um sistema capaz de aprender de forma autônoma qualquer área da ciência e colaborar com cientistas humanos, propondo novas hipóteses e experimentos originais.</div> </div> </div> <div style="border: 1px solid #ccc; padding: 10px;"> <p>Super AI</p> <div style="border: 1px solid #ccc; padding: 5px; background-color: #e0e0ff; width: 100%;">Uma inteligência artificial capaz de gerar formas totalmente novas de arte, música e matemática, incompreensíveis para os seres humanos.</div> </div>	IA-1.1.2	K2	1

Q	RC	Explicação / Fundamentação	OA	K	P
		<p>Explicação / Fundamentação</p> <p>Considerando cada um dos sistemas de exemplo, um por um:</p> <ul style="list-style-type: none"> • Uma mente artificial que gera formas totalmente novas de arte, música e matemática, incompreensíveis para os seres humanos. <p>Esse sistema demonstra criatividade e inteligência muito além da capacidade humana, produzindo resultados incompreensíveis para as pessoas. Tais habilidades superam tanto a inteligência geral de nível humano quanto qualquer inteligência artificial geral atual; portanto, este é um exemplo de super IA.</p> <ul style="list-style-type: none"> • Um sistema que gerencia agendas diárias complexas, aprende novas receitas a partir de um vídeo e mantém conversas sobre romances que acabou de ler. <p>Essa IA realiza uma ampla gama de tarefas complexas que exigem aprendizagem, percepção, planejamento e compreensão da linguagem, comparáveis à versatilidade de um ser humano. Ela demonstra adaptabilidade e competência em domínios inéditos. Portanto, trata-se de um exemplo de IAG.</p> <ul style="list-style-type: none"> • Um sistema capaz de aprender de forma independente qualquer campo da ciência e colaborar com cientistas humanos, propondo hipóteses inovadoras e experimentos originais. <p>Esse sistema tem a capacidade de dominar de forma autônoma e com flexibilidade múltiplas disciplinas científicas e se envolver em pesquisas criativas. Sua competência abrange aprendizagem, raciocínio e pensamento inovador no nível de um especialista humano. Portanto, é um exemplo de IGA.</p> <ul style="list-style-type: none"> • Um sistema que examina imagens radiológicas para detectar as características específicas de tumores cancerígenos. <p>Essa IA se destaca em uma tarefa bem definida e especializada (análise de imagens médicas) sem compreensão ou habilidades mais amplas fora de seu domínio. Sua aplicação se limita ao reconhecimento de padrões dentro de dados radiológicos e não se estende à cognição generalizada. Portanto, trata-se de um exemplo de IA estreita.</p> <ul style="list-style-type: none"> • Um modelo de tradução de idiomas capaz de converter texto escrito do francês para o espanhol. 			

Q	RC	Explicação / Fundamentação	OA	K	P
		Este modelo foi construído para desempenhar uma única função — traduzir entre dois idiomas. Ele demonstra especialização em uma tarefa delimitada e não possui compreensão abrangente ou adaptabilidade além da conversão de idiomas. Portanto, é um exemplo de IA estreita.			
A2	a	<p>a) Correto. A construção de modelos é uma função essencial, e os frameworks de desenvolvimento de ML fornecem “ferramentas para definir a arquitetura do modelo ML”, incluindo a capacidade de especificar a estrutura do modelo ML, como uma árvore de decisão.</p> <p>b) Incorreto. A palavra “eliminar” é um exagero. Os frameworks de desenvolvimento de ML auxiliam, mas não eliminam a necessidade de pré-processamento de dados. O tratamento de dados é uma função de suporte que não realiza automação completa, eliminando a tarefa.</p> <p>c) Incorreto. As estruturas de desenvolvimento de ML existem em diferentes níveis de abstração, incluindo “uma API de nível superior, simplificando a criação de modelos”. Isso sugere que a programação não é um requisito universal, com a seleção do framework dependendo da “experiência dos usuários”.</p> <p>d) Incorreto. Não é correto afirmar que os frameworks de desenvolvimento de ML prendem os modelos ML desenvolvidos a esse framework. Geralmente, qualquer modelo ML desenvolvido pode ser implantado em qualquer lugar (dentro do razoável).</p>	AI-1.1.7	K2	1
A3	c	<p>a) Incorreto. A norma ISO/IEC/IEEE TR 29119-11 não trata de testes de IA, mas, como todas as normas, fornece diretrizes e não impõe penalidades por não conformidade.</p> <p>b) Incorreto. A OCDE é um conjunto de diretrizes não obrigatórias.</p> <p>c) Correto. Se o sistema estiver abrangido pela Lei de IA da UE (ou seja, se for utilizado na Europa), o não cumprimento de uma abordagem baseada no risco pode resultar em penalidades de severidade elevada.</p> <p>d) Incorreto. A ISO/IEC 25059 descreve as características de qualidade exclusivas dos sistemas de IA, mas, como todas as normas, fornece diretrizes em vez de impor penalidades por não conformidade.</p>	IA-1.1.8	K2	1
A4			IA-3.1.1	K2	1

Q	RC	Explicação / Fundamentação	OA	K	P
		<div style="display: flex; justify-content: space-between;"> <div style="width: 30%;"> <p>Associação</p> <p>Classificação</p> <p>Aprendizado por reforço</p> <p>Regressão</p> </div> <div style="width: 65%;"> <p>Uma empresa de energia utiliza dados meteorológicos históricos e os números correspondentes de consumo diário de energia para prever a quantidade total de eletricidade de que uma cidade precisará amanhã</p> <p>Um braço robótico aprende a classificar corretamente vários objetos em diferentes caixas, recebendo uma recompensa positiva por cada objeto colocado na caixa correta e uma penalidade por cada erro</p> <p>Um sistema de inteligência artificial aplicado à agricultura analisa imagens de satélite de culturas, que foram classificadas por botânicos como 'saudáveis' ou 'doentes', para identificar áreas de uma fazenda que necessitam de tratamento</p> <p>Um sistema de pesquisa médica analisa prontuários de pacientes e identifica uma forte associação entre um marcador genético específico e o aparecimento precoce de uma determinada doença</p> </div> </div> <p>Explicação / Fundamentação</p> <p>Considerando cada uma das descrições dos sistemas de exemplo, de cima para baixo:</p> <ul style="list-style-type: none"> • Associação — Este sistema utiliza associação por meio da mineração de registros de pacientes não rotulados para identificar dependências entre diferentes atributos, como um gene e uma doença. Ele não prevê uma classe, mas revela a força da relação entre variáveis dentro dos dados. • Classificação - Ele aprende a partir de um conjunto de dados de imagens que foram pré-rotuladas com categorias discretas ("saudável" ou "doente"). Seu objetivo é categorizar novas imagens em uma dessas classes específicas e não numéricas, distinguindo-se da regressão. • Aprendizado por reforço - O sistema aprende por meio da interação direta com seu ambiente físico, e não a partir de um conjunto de dados pré-existente. O comportamento do robô é moldado ao longo do tempo por um sistema de recompensas (para posicionamento correto) e penalidades (para posicionamento incorreto). 			

Q	RC	Explicação / Fundamentação	OA	K	P
		<ul style="list-style-type: none"> Regressão - O modelo ML é treinado em dados rotulados para prever um valor numérico específico e contínuo: a quantidade de eletricidade. A saída do modelo não é uma categoria, mas uma quantidade em uma escala, o que é a característica principal da regressão. 			
A5		<p>Resposta correta:</p> <p>1 Preparar e testar os dados de teste</p> <p>3 Testar o modelo</p> <p>5 Monitorar e ajustar o modelo</p> <p>2 Avaliar o modelo</p> <p>4 Implantar o modelo</p> <p>Explicação/Fundamentação</p> <pre> graph TD subgraph Fluxo_ML [Fluxo ML] subgraph Desenvolvimento_de_modelos [Desenvolvimento de modelos] direction TB A[Compreender os objetivos] --> B[Preparar e testar os dados] A --> C[Selecionar um Framework] C --> D[Selecionar e construir o algoritmo] D --> E[Treinar o modelo] E --> F[Avaliar o modelo] F --> G[Ajustar o modelo] G --> E end subgraph Geracao_e_teste_de_modelos [Geração e teste de modelos] direction TB H[Testar o modelo] end B --> H H --> I[Implantar o modelo] I --> J[Monitorar e ajustar o modelo] J --> E I --> K[Usar o modelo] end </pre>	AI-3.1.2	K2	1

Q	RC	Explicação / Fundamentação	OA	K	P
A6	c	<p>a) Incorreto. A limitação principal é o raciocínio interno do modelo, um problema geral aplicável a muitas tarefas, não especificamente àquelas que envolvem feedback humano.</p> <p>b) Incorreto. A cobertura estrutural é um método para avaliar a exaustividade dos testes de um único modelo, não para comparar modelos diferentes. Embora o tamanho do modelo possa afetar os números brutos de cobertura, os valores calculados são normalmente apresentados como porcentagens e, portanto, isso não é uma limitação para o seu propósito pretendido.</p> <p>c) Correto. Aborda diretamente as principais limitações das medições de cobertura usadas isoladamente. As redes neurais podem aprender correlações espúrias, levando a ativações corretas por motivos incorretos, o que significa que o modelo poderia atingir alta cobertura estrutural enquanto toma decisões com base em características irrelevantes.</p> <p>d) Incorreto. A cobertura estrutural é um complemento valioso que deve ser combinado com outros métodos. Seu objetivo é aprimorar, e não substituir, outras atividades de teste, como a avaliação da correção funcional e da utilidade das saídas do modelo.</p>	AI-3.4.3	K2	