

ISTQB.CT-AI.v2026-02-20.q71

試験コード:	CT-AI
試験名称:	Certified Tester AI Testing Exam
認定資格:	ISTQB
無料問題数:	71
バージョン:	v2026-02-20
アクセス数:	122
ページビュー数:	710
https://www.jpnpdf.com/ISTQB.CT-AI.v2026-02-20.q71-mondaishu.html	

最新問題: 1

患者が脳卒中のリスクがあるかどうかを予測しようとする機械学習モデルを考えてみましょう。このモデルは、各患者の血圧、赤血球数、喫煙状況、心疾患の既往歴、コレステロール値、人口統計に関する情報を収集します。そして、決定木を用いて、関連患者が近い将来に脳卒中を起こす可能性が高いかどうかを予測します。トレーニングデータセットを用いてモデルを作成した後、さらに80人の患者の脳卒中を予測します。以下の表は、モデルが正しい予測を行ったか、あるいは正しくなかったかを示す混同行列を示しています。

テスターたちは、このモデルに適切な機能パフォーマンス指標であると考えられる値を計算しました。その結果、2/3、つまり0.6667という値が算出されました。

- A. F1 -ソース
- B. 精度
- C. リコール
- D. 精度

Answer: D (メッセージを残す)

この問題は、患者が脳卒中のリスクがあるかどうかを予測する分類モデルについて記述しています。混同行列が提供されており、テスターはパフォーマンス指標を2/3、つまり0.6667と計算しました。

ISTQB 認定テスター AI テスト (CT-AI) シラバスによると、混同行列からの機能パフォーマンスメトリックの定義には次のものが含まれます。

* 正確さ :

$$\text{精度} = (TP + TN) / (TP + TN + FP + FN)$$

$$\text{精度} = \frac{TP + TN}{TP + TN + FP + FN}$$

* データセット全体に対して正しく分類されたインスタンス (真陽性と真陰性の両方) の割合を測定します。

* 値が 0.6667 の場合、メトリックには正しい正の分類と負の分類の両方が含まれており、精度と一致していることを示します。

* 精度:

$$\text{精度} = \frac{\text{TP}}{\text{TP} + \text{FP}}$$

* 予測された陽性症例のうち実際に陽性であった症例の数を測定します。

* 指定された計算と一致しません。

* 再現率 (感度)

$$\text{想起} = \frac{\text{TP}}{\text{TP} + \text{FN}}$$

* 実際に陽性と正しく識別された数を測定します。

* 0.6667 の値と一致しません。

* F1スコア:

$$F1 = 2 \times \frac{\text{適合率} \times \text{再現率}}{\text{適合率} + \text{再現率}}$$

$$F1 = 2 \times \frac{\text{適合率} \times \text{再現率}}{\text{適合率} + \text{再現率}}$$

* 精度と再現率のバランス。

* 計算式は提供されている計算とは異なります。

精度の式は計算値 0.6667 と一致するため、最適な答えは D. 精度です。

認定テスター AI テスト学習ガイド 参考文献:

* ISTQB CT-AI シラバス v1.0、セクション 5.1 (混同行列と機能パフォーマンス メトリクス)

* ISTQB CT-AI シラバス v1.0、セクション 5.4 (ML 機能パフォーマンス メトリクスの選択)

最新問題: 2

次のうち、前処理を使用して解決できるデータセットの問題はどれですか？

A. データが不十分です

B. 無効なデータ

C. 外れ値を求める

D. 文字列として保存された数値

Answer: (解答を表示する)

前処理は、データ準備において不可欠なステップです。データがクリーンで、正しくフォーマットされ、機械学習 (ML) モデルの効果的なトレーニングのために構造化されていることを保証するものです。前処理中に解決できる一般的な問題の一つは、数値が文字列として保存されていることです。

回答の選択肢の説明:

* オプションA: データ不足

* 不正解です。前処理では不十分なデータを解決することはできません。データが不足している場合は、データ拡張や外部データ収集などの手法が必要です。

* オプションB: 無効なデータ

* 不正解です。前処理によって一部の無効なデータ (欠損値 重複エントリなど) を識別して処理することは可能ですが、すべての無効なデータに関する問題を解決できるわけではありません。場合によっては、妥当性を判断するために専門知識が必要になる場合があります。

* オプションC: 外れ値を求める

* 不正解です。前処理は通常、不要な外れ値の処理に重点を置きます。必要な外れ値も保持する必要がある場合がありますが、これは前処理というよりもむしろデータ選択の決定です。

* オプションD: 数値を文字列として保存する

* 正解です。データ前処理の重要な機能の 1 つはデータ変換です。これには、文字列として保存された数値など、形式が誤っているデータ型を正しい数値形式に変換することが含まれます。

ISTQB CT-AI シラバス参考文献:

* データ前処理手順: 変換: 指定されたデータの形式が変更されます (例: 文字列として保持されているアドレスを構成要素に分割する、ランダム識別子を保持するフィールドを削除する、カテゴリ データを数値データに変換する、画像形式を変更する)。

最新問題: 3

次のどれが、連続テストの状況について最も説明が少ないでしょうか?

1つのオプションを選択

A. 同じデータに対して、プラットフォーム A (たとえば Pytorch) で実装された現在のニューラル ネットワーク モデル ML モデルの結果と、プラットフォーム B (たとえば Tensorflow) で実装された同様のニューラル ネットワーク モデル ML モデルの結果を比較します。

B. 同じデータに対して、自作ニューラルネットワークモデル ML モデルの結果と、標準実装 (たとえば Pytorch) で実装されたニューラルネットワークモデルの結果を比較します。

C. 同じデータに対するニューラル ネットワーク ML モデルの結果と現在の決定木 ML モデルの結果の比較。

D. 現在のデータ セットに対する現在のニューラル ネットワーク ML モデルの結果を、わずかに変更したデータ セットと比較します。

Answer: ([解答を表示する](#))

バックツーバックテストとは、システムの複数の実装に対して同じテストセットを実行し、それらの出力を比較する手法です。このタイプのテストは、通常、異なる実装の出力を同一条件下で比較することで、一貫性と正確性を確認するために使用されます。以下の選択肢を分析してみましょう。

A. プラットフォーム A (Pytorch など) で実装された現在のニューラル ネットワーク モデル ML モデルと、プラットフォーム B (Tensorflow など) で実装された同様のニューラル ネットワーク モデル ML モデルの結果の、同じデータに対する比較。

このオプションは、同じデータセットを用いて、同じ種類のモデルの2つの異なる実装を比較するシナリオを表します。これは典型的なバックツーバックテストの状況です。

B. 同じデータに対して、自社開発のニューラル ネットワーク モデル ML モデルの結果と、標準実装 (Pytorch など) で実装されたニューラル ネットワーク モデルの結果を比較します。

このオプションでは、カスタム実装と標準実装を比較します。これは、カスタム モデルを既知のベンチマークに対して検証するための一般的なバックツーバック テスト シナリオでもあります。

C. 同じデータに対するニューラルネットワークMLモデルと現在の決定木MLモデルの結果の比較。

このオプションでは、2つの異なる種類のモデル (ニューラルネットワークと決定木) を比較します。これらのモデルは本質的に異なるため、同じデータであっても同一の結果を出すことは期待できないため、これはバックツーバックテストの典型的なシナリオではありません。

D. 現在のデータセットに対する現在のニューラルネットワークMLモデルの結果を、わずかに変更したデータセットと比較します。

このオプションでは、わずかに異なるデータセットで同じモデルの出力を比較します。これはロバスト性テストや感度分析の一種と見なすことができますが、複数の実装を比較する必要がないため、典型的なバックツーバックテストとは異なります。

この分析に基づくと、オプションCは、根本的に異なる2つのモデルを比較するものであり、バックツーバックテストの意図するところではないため、バックツーバックテストの状況を最も説明していないオプションです。

最新問題: 4

バイクのエンジン修理工場のオーナーは、排気バルブの漏れを検知し、故障してエンジンに壊滅的な損傷を与える前に修理したいと考えています。そこで、正常なエンジンと排気バルブの故障により壊滅的な故障を経験したエンジンの履歴データファイルを用いて予測モデルを開発・学習しました。このモデルを用いて200台のエンジン进行评估し、その後、エンジンを分解してバルブの真の状態を評価し、その結果を下の混同行列に記録しました。

	Actual - positive	Actual - negative	Total
Predicted - positive	90	10	100
Predicted - negative	1	99	100
Total	91	109	200

この予測モデルの精度はどのくらいでしょうか？

- A. 90.0%
- B. 94.5%
- C. 98.9%
- D. 94.2%

Answer: B ([メッセージを残す](#))

シラバスでは精度を次のように定義しています。

適合率 = $TP / (TP + FP) * 100\%$ 。適合率は、正しく予測された陽性の割合を測定します。」混同行列の使用：

TP = 90

* FP = 10したがって、精度 = $(90 / (90 + 10)) * 100\% = 90 / 100 * 100\% = 90\%$ ただし、混同行列の合計から、計算は次の形式で行う必要があることがわかります。精度 = $90 / (90 + 10) * 100\% = 90\%$ 与えられた回答にはちょうど90%が含まれていないため、シラバスに記載されている最も近い近似値と正解は90%になります。(参照: ISTQB CT-AIシラバスv1.0、セクション 5.1、99ページ中40ページ)

最新問題: 5

データのラベル付けが誤っている理由として次のどれが考えられますか？

- A. ドメイン知識の欠如
- B. 専門知識
- C. 相互運用性エラー
- D. 小さなデータセット

Answer: A ([メッセージを残す](#))

シラバスには、ドメイン知識の欠如など、データのラベル付けが誤っている複数の理由が挙げられています。

必要なドメイン知識が不足すると、ラベル付けが不正確になる可能性があります。」

(参照ISTQB CT-AIシラバスv1.0、セクション4.5.2、99ページ中38ページ)

最新問題: 6

あるビール会社は、自社のロゴが市場でどの程度認知されているかを把握しようとしています。同社は、ロゴ検出用に事前学習済みのニューラルネットワークを用いて、様々なソーシャルメディアプラットフォーム上の画像をモニタリングすることで、その調査を計画しています。このモデルは、ソーシャルメディアの画像から単語を探すだけでなく、色を合わせることで学習されています。会社のロゴは、中央に大きな文字が書かれ、太い青とマゼンタの枠で囲まれています。

この事前トレーニング済みモデルを使用する場合、どの関連リスクが発生する可能性が最も高いですか？

- A. モデルはすでにトレーニング済みなのでリスクはありません
- B. 機能が不十分: モデルは色や単語をチェックするようにトレーニングされていません
- C. 不適切なデータ準備
- D. 継承バイアス: モデルは未知の欠陥を継承している可能性がある

Answer: D ([メッセージを残す](#))

シラバスによると、事前学習済みモデルは、元の学習で使用されたデータやプロセスからバイアスや制限を継承することが多く、新しいユースケースに適合しない可能性があります。具体的には、シラバスには次のように記載されています。

事前学習済みモデルを使用する場合、学習データと学習プロセスはモデルのユーザーによって完全に制御または把握できません。その結果、モデルは元の開発および学習プロセスの一部であったバイアスや不正確さを継承する可能性があります。(参照ISTQB CT-AIシラバスv1.0、セクション1.8.3)

最新問題: 7

X線画像を使って肺がんを検出するシステムが開発される予定です。

従来のシステムと教師あり機械学習を備えた AI システムの違いを最もよく説明している記述はどれですか？

4つの中から1つを選択してください

- A. AI システムはトレーニング中に X 線のパターンを独自に決定します。従来のシステムでは、人間がそれらのパターンをプログラムする必要があります。

B. AI システムが分析できる X 線画像は、従来のシステムで使用される X 線画像とは構造的に異なる必要があります。

C. AI システムを使用して肺がんの X 線写真を分析した結果は、従来のシステムよりも理解しやすくなっています。

D. AI システムの実装は主にトレーニング データで構成されますが、従来のシステムの実装は分岐とループで構成されます。

Answer: (解答を表示する)

シラバスのセクション1.3 AIベースシステムと従来型システム」では、従来型システムと教師あり機械学習を用いたAIベースシステムの根本的な違いを解説しています。従来型システムは、入力データを解釈するために、分岐、条件、明示的なルールなど、人間がプログラムしたロジックに依存しています。

システムは開発者が指定したとおりに動作します。

対照的に、教師あり学習を用いるAIシステムは、ラベル付けされたデータからパターンを自動的に学習します。シラバスには、データ内のパターンは、システムが将来どのように反応すべきかを決定するために用いられる」と記されています。

AI はデータ内のどのパターンや特徴が使用できるかを独自に決定します。これはオプション C と直接一致します。AI システムはトレーニング中に X 線画像内の関連する診断パターンを識別しますが、従来のシステムでは人間の専門家がそれらのパターンを明示的にプログラムする必要があります。

選択肢Aは不正解です。AIの出力は通常、説明可能性が高くなるのではなく、低くなるからです。選択肢Bは不正解です。どちらのシステムも同じX線画像を使用できますが、機械学習では構造的に異なる画像は必要ありません。選択肢Dは単純化しすぎていて、完全に正確ではありません。学習データは機械学習の中心ですが、AIシステムにはデータだけでなく、アーキテクチャ、アルゴリズム、前処理も含まれます。

したがって、オプション C はシラバスに準拠した正しい回答です。

最新問題: 8

ある野生生物保護団体は、ニューラルネットワークを用いて様々な動物の画像を分類したいと考えています。このアルゴリズムは、ソーシャルメディアプラットフォームで、今月の動物として選ばれた動物の写真を自動的に選出するために利用される予定です。今月の動物はオオカミです。テストチームは既に、犬とオオカミの特徴が類似していることから、このアルゴリズムが犬の写真をオオカミとして分類できることを確認済みです。このような状況に対応するため、チームはオオカミと犬の画像を追加してモデルをトレーニングし、モデルがオオカミと犬の区別をより正確に行えるようにする予定です。

追加トレーニング後にモデルが改善されたことを確認するには、どのようなテスト方法を使用する必要がありますか？

A. この時点ではアプリケーションドメインが明確に理解されていないため、メタモーフィックテストが行われます。

B. トレーニングで誤った画像が使用されていないことを確認するための敵対的テスト

C. 組み合わせ論を用いたペアワイズテストで写真パラメータの長いリストを調べる

D. トレーニング前のモデルのバージョンと、追加画像でトレーニングした後の新しいバージョンのモデルを使用したバックツーバックテスト

Answer: D ([メッセージを残す](#))

シラバスでは、バックツーバック テストは、修正された AI システムを以前のバージョンと比較する方法として定義されており、次のシナリオに最適です。

「バックツーバックテストは、同じ出力を提供すると想定される2つのシステムの出力を比較することによって行われます。1つは既知の信頼できるシステム、もう1つはテストシステムです。このアプローチは、再学習後の機械学習システムをテストし、改善によって回帰が発生していないことを確認するために使用できます。」（参照ISTQB CT-AIシラバスv1.0、セクション9.3、99ページ中67ページ）

最新問題: 9

急速に変化する市場において、デイトレーダーが商品の売買効率を向上させることを支援するニューラルネットワークが設計・構築されました。テストチームがニューラルネットワーク上で各ニューロンを検査するテストを実行するとします。このネットワークでは、最短経路は買いを示し、商品の1日予測値がスポット価格を0.75%上回る場合にのみ買いが行われます。ニューロンは商品価格を入力することで刺激され、テスターは将来価格がスポット価格を少なくとも0.75%上回る場合にのみ活性化することを確認します。

ニューラル ネットワークでテストされるカバレッジの種類を最もよく説明している記述は次のどれですか。

A. 閾値カバレッジ

B. ニューロンカバレッジ

C. 符号変化カバレッジ

D. 値変更カバレッジ

Answer: A ([メッセージを残す](#))

閾値カバレッジは、ニューラルネットワークのテストで使用されるカバレッジ指標の一種です。ネットワーク内の各ニューロンが、指定された閾値を超える活性化値を達成することを保証します。これは、特に、商品の将来価値がスポット価格を少なくとも0.75%上回った場合にのみニューロンが活性化することをテスターが検証するという、前述のシナリオに関連します。

* 閾値ベースの活性化: 質問のテストケースは、特定の閾値 (0.75%) を超えた場合にのみニューロンが活性化するかどうかを明示的に検証しています。これは、閾値カバレッジの定義と完全に一致しています。

* ニューラル ネットワーク テストで一般的: しきい値カバレッジは、ニューラル ネットワーク内の各ニューロンが指定されたアクティビティ化値に達するかどうかを測定するのに使用され、さまざまなテスト入力にさらされたときにニューラル ネットワークが期待どおりに動作することを確認します。

* 研究における前例:DeepXplore フレームワークは、ニューラル ネットワーク内の誤った動作を識別するために 0.75% のしきい値を使用しており、このカバレッジ基準は AI テスト研究で十分に文書化されています。

* (B) ニューロンカバレッジ#

* ニューロンカバレッジは、テスト中のある時点でニューロンが活性化（非ゼロ値）するかどうかのみをチェックします。特定の活性化閾値は考慮されないため、このシナリオでは精度が低くなります。

* (C) サインチェンジカバレッジ#

* このカバレッジでは、各ニューロンが正と負の両方の活性化値を示しているかどうかを測定しますが、これは特定のシナリオには関係ありません (活性化は特定のしきい値を超えた場合にのみ重要になります)。

* (D) 価値変動補償#

* このカバレッジでは、各ニューロンが選択したしきい値によって異なる 2 つの活性化値を生成する必要がありますが、質問は活性化値の変化ではなく、固定しきい値を超えて活性化が発生するかどうかに関心があります。

* 閾値カバレッジは、ニューロンが特定の活性化閾値を超えることを保証します。完全な閾値カバレッジには、ニューラルネットワーク内の各ニューロンが指定された閾値を超える活性化値を達成する必要があります。DeepXploreフレームワークを作成した研究者は、ニューロンカバレッジは、状況に応じて変化する閾値を超える活性化値に基づいて測定されるべきであると提案しました。」閾値カバレッジが正しい理由他の選択肢が間違っている理由ISTQB認定テスターAIテスト学習ガイドからの参照したがって、選択肢Aが正解です。閾値カバレッジは、ニューラルネットワークの活性化が必要な条件 (0.75%) に基づいて正しく評価されることを保証します。

最新問題: 10

ML ワークフローにおけるデータ準備に関して正しい記述はどれですか。

4つの中から1つを選択してください

A. データ変換における重要な課題は、誤ったデータの削除または修正です。

B. データの準備には時間がかかるため、すべての手順を自動化する必要があります。

C. データ収集における課題の 1 つは、複数のソースから高品質のデータを取得することです。

D. サンプリングについては十分に研究されているため、もはやリスクがあるとは考えられていません。

Answer: C ([メッセージを残す](#))

ISTQB CT-AI シラバスのセクション 2.2 「データ準備」で、ML データ準備ワークフローについて説明しています。

データ準備は、データ収集、クレンジング、変換、そしてサンプリングから構成されます。シラバスでは、データ収集における重要な課題の一つとして、構造、品質、形式が異なる複数の異種ソースからのデータを統合することの重要性を強調しています。結果として得られるデータセットの正確性、完全性、そして代表性を確保することは複雑であり、MLワークフローにおける重要な課題となっています。

これはオプションCと直接一致します。

選択肢Aは不正解です。誤ったデータ修正はクリーニングの一部であり、変換の一部ではないからです。選択肢Bはシラバスに矛盾しています。自動化は確かに役立ちますが、特に微妙なデータ品質の問題を検出する際には専門家の監視が必要となるため、すべてのステップを自動化すべきではありません。選択肢Dは不正解です。サンプリングには、特に代表性に関してリスクが伴い、シラバスは自己満足ではなく注意を重視しているからです。

したがって、OptionC はシラバスを正確に反映する唯一のステートメントです。

最新問題: 11

ディープ ニューラル ネットワークのレイヤーに関して正しいのは次のうちどれですか。

- A. 入力層と出力層のみが存在する
- B. 少なくとも1つの内部隠れ層がある
- C. 深い層とみなされるには、少なくとも合計5つの層が必要です。
- D. 出力層は整合性を維持するために他の層と接続されていません

Answer: B ([メッセージを残す](#))

ディープニューラルネットワーク (DNN) は、入力層と出力層の間に複数の層で構成される人工ニューラルネットワークの一種です。ISTQB認定テストAIテスト (CT-AI) シラバスでは、DNNの以下の特徴について概説しています。

* ディープニューラルネットワークの構造:

* ADNN は少なくとも 3 種類のレイヤーで構成されています。

* 入力層: 入力データを受信します。

* 隠しレイヤー: 複雑な特徴の抽出と変換を実行します。

* 出力層: 最終的な予測または分類を生成します。

* 回答選択肢の分析:

* A (入力層と出力層のみ) # 誤り。DNN には少なくとも 1 つの隠し層が必要です。

* B (少なくとも 1 つの内部隠し層) # 正解です。ニューラル ネットワークが深いと見なされるには、隠し層が必要です。

* C (最低 5 層必要) # 少なくとも 5 層を必要とする厳密な定義がないため、誤りです。

* D (出力層は他の層に接続されていません) # 出力層は隠し層に接続されている必要があるため、不正解です。

したがって、ディープ ニューラル ネットワークには少なくとも 1 つの隠し層が必要なため、オプション B が正解です。

認定テストAI テスト学習ガイド 参考文献:

* ISTQB CT-AI シラバス v1.0、セクション 6.1 (ニューラル ネットワークとディープ ニューラル ネットワーク)

* ISTQB CT-AI シラバス v1.0、セクション 6.2 (ディープ ニューラル ネットワークの構造)。

最新問題: 12

Splendid Healthcare」は、機械学習 (ML) を基盤としたがん検出システムの開発を開始しました。彼らが検出を予定しているがんは、特定の地域における人口の有病率が2%です。このモデルは、健常者とがん患者の両方に対して良好な性能を発揮することが求められています。

次の組み合わせのうち、最大化が必要なものはどれですか？

1つのオプションを選択

- A. 精度と正確さを最大化する
- B. 精度と再現率を最大化する
- C. 再現率と精度を最大化する
- D. クラスの詳細度を最大化する

Answer: C (メッセージを残す)

有病率とモデルのパフォーマンス:

Splendid Healthcare」が開発中のがん検出システムでは、この種類のがんの有病率が人口の2%であるという事実を考慮する必要があります。これは、データセットが陽性 (がん) 症例数と陰性 (正常) 症例数を大幅に比較すると、非常に不均衡であることを示しています。

リコールの重要性:

再現率 (感度または真陽性率とも呼ばれる) は、モデルによって正しく識別された実際の陽性症例の割合を測定します。医療診断、特になんか検出においては、陽性症例の見逃し (偽陰性が患者に深刻な影響を及ぼす可能性があるため、再現率は非常に重要です。したがって、再現率を最大化することで、すべてのがん症例ではないにしても、大部分のがん症例を検出できるようになります。

精度の重要性:

精度は、予測された陽性症例のうち実際に陽性であった症例の割合を測定します。精度が高いほど偽陽性の数が減り、がんと誤って診断される人の数が少なくなります。これは、がんを患っていない人への不必要な不安や、さらなる侵襲的な検査を避けるためにも重要です。

再現率と精度のバランス:

偽陰性と偽陽性の両方が重大な結果をもたらすシナリオでは、再現率と適合率のバランスをとることが極めて重要です。このバランスにより、モデルは陽性ケースの検出に優れているだけでなく、予測精度も向上し、両方の種類のエラーを削減できます。

正確性と特異性:

精度 (正しい予測全体の割合) は重要ですが、不均衡なデータセットでは誤解を招く可能性があります。この場合、高い精度は、モデルが多数派クラス (正常を正しく予測したというだけのことも) かもしれません。特異度 (真陰性率) も重要ですが、がん検出システムでは、陽性症例を正確かつ正確に特定するために、再現率と適合率が優先されます。

結論:

したがって、有病率の低い癌検出システムでは、癌症例の効果的かつ正確な検出を確実にするために、再現率と精度の両方を最大化することが重要です。

あるビール会社は、自社のロゴが市場でどの程度認知されているかを把握しようとしています。同社は、ロゴ検出用に事前学習済みのニューラルネットワークを用いて、様々なソーシャルメディアプラットフォーム上の画像をモニタリングすることで、その調査を計画しています。このモデルは、ソーシャルメディアの画像から単語を探すだけでなく、色を合わせることで学習されています。会社のロゴは、中央に大きな文字が書かれ、太い青とマゼンタの枠で囲まれています。

この事前トレーニング済みモデルを使用する場合、どの関連リスクが発生する可能性が最も高いですか？

- A. モデルはすでにトレーニング済みなのでリスクはありません
- B. 機能が不十分です。モデルは色や単語をチェックするようにトレーニングされていません。
- C. 不適切なデータ準備
- D. 継承バイアス: モデルは未知の欠陥を継承している可能性がある

Answer: D (メッセージを残す)

ロゴ検出に事前学習済みのニューラルネットワークを使用する際の大きなリスクは、元のデータセットや学習プロセスからバイアスや欠陥が引き継がれる可能性があることです。つまり、モデルが以下の理由により、特定のロゴを誤認したり、認識できなかったりする可能性があります。

* データ準備の違い: 元のトレーニング データでは、新しいデータセットとは異なる前処理方法が使用されていた可能性があり、不一致が生じています。

* 透明性が限られている: データセットの正確な詳細と其中的のバイアスが不明な場合があり、予期しない動作が発生する可能性があります。

* ロゴ検出における偏り: モデルが特定の色またはテキスト設定を持つデータセットでトレーニングされた場合、類似した特性を持つロゴを不当に誤認する可能性があります。

この継承された偏見により、次のような結果が生じる可能性があります。

* 誤検知: 他のブランドのロゴをビール会社のロゴとして認識する。

* 偽陰性: バリエーションが発生した場合 (例: 照明の違いや部分的な可視性など)、実際のロゴを検出できない。

* アルゴリズムの偏り: 偏ったトレーニング データにより、モデルが特定の形状や色のコントラストを優先する場合があります。

したがって、この事前トレーニング済みモデルの使用に関連する最も適切なリスクは、継承されたバイアスです。

* セクション 1.8.3 - 事前トレーニング済みモデルと転移学習の使用のリスクでは、事前トレーニング済みモデルが新しい環境でのパフォーマンスに影響を与えるバイアスや文書化されていない欠陥を継承する可能性がある方法について説明します。

ISTQB認定テスターAIテスト学習ガイドからの参考資料:

最新問題: 14

AIベースのシステムを導入する前に、開発者はテスト環境で意思決定がどのように行われるかを実証することが求められます。意思決定は以下のどの特性に該当しますか？

- A. 説明可能性
- B. 自律性

C. 自己学習

D. 非決定性

Answer: A (メッセージを残す)

AIベースのシステムにおける説明可能性とは、システムが特定の結果に至った経緯をユーザーが容易に理解できることを指します。これは、AIモデルによる意思決定が透明性、解釈可能性、そして利害関係者にとって理解しやすいものであることを保証するため、AIによる意思決定を実証する上で非常に重要な要素です。

AIベースのシステムを導入する前に、開発者はテスト環境で意思決定がどのように行われるかを検証する必要があります。このプロセスは説明可能性という特性を持ちます。AIモデルがどのようにして結論に至ったかを明確にするプロセスであり、システムへの信頼を構築し、規制および倫理的要件を満たすのに役立ちます。

* ISTQB CT-AI シラバス セクション 2.7: 透明性、解釈可能性、説明可能性)

* 説明可能性とは、AI ベースのシステムが特定の結果をどのように導き出したかをユーザーが判断できる容易さであると考えられます」。

* ほとんどのユーザーはAIベースのシステムを『ブラックボックス』として提示され、これらのシステムがどのように結果に辿り着くのかをほとんど認識していません。こうした無知は、システムを構築したデータサイエンティストにも当てはまる可能性があります。場合によっては、ユーザーはAIベースのシステムを操作していることさえ認識していないこともあります。」

* ISTQB CT-AI シラバス (セクション 8.6: AI ベース システムの透明性、解釈可能性、説明可能性のテスト)

* AIベースのシステムの説明可能性をテストするには、ユーザーがAIが生成した意思決定を理解し、検証できるかどうかを検証する必要があります。これにより、AIシステムが説明責任を果たし、理解不能な意思決定や偏った意思決定を行わないことが保証されます。」

* 他のオプションとの対比:

* 自律性 (B): 自律性とは、AIシステムが人間の監視なしに独立して動作する能力を指します。意思決定は自律性の重要な機能ですが、ここでは意思決定の根拠を示すことに重点が置かれており、これは自律性ではなく説明可能性に該当します。

* 自己学習 (C): 自己学習システムは過去のデータや経験に基づいて適応しますが、これは人間が理解できる意思決定とは異なります。

* 非決定性 (D): AIベースのシステムは多くの場合、確率的かつ非決定的であり、同じ入力に対して常に同じ出力を生成するとは限りません。これはテストと検証を困難にする可能性があります。が、意思決定プロセスの説明とは関係ありません。

ISTQB 認定テストターの AI テスト学習ガイドからのサポート参考文献: 結論: この質問は、展開前に実証される際に意思決定が該当する特性について明示的に尋ねているため、説明可能性が正しい選択です。説明可能性により、AI の決定が透明性があり、理解しやすく、利害関係者に対して説明責任があることが保証されるからです。

テキストメッセージに次に入力する単語を予測する自然言語処理 (NLP) アルゴリズムを考えてみましょう。このアルゴリズムには、ユーザーの入力パターンに基づいた予測精度を向上させるアップデートが作成されました。以前のアルゴリズムの精度はユーザーによって評価されました。その後、新しいアップデートがリリースされた後、ユーザーはアップデートされたアルゴリズムを評価しました。統計的検定を用いて2つのバージョンのアルゴリズムを比較し、アップデートを継続すべきかどうかを判断しました。

これはどのようなタイプのテストの例ですか？

- A. メタモルフィックテスト
- B. A/Bテスト
- C. 探索的テスト
- D. ペアワイズテスト

Answer: B ([メッセージを残す](#))

シラバスには次のように記載されています。

A/Bテストは、第5章で説明されているように、ML機能のパフォーマンスメトリクスなどの合意された受け入れ基準があるAIベースシステムの更新をテストするために使用できます。A/Bテストは、更新されたバリエーションを以前のバリエーションと比較するために使用されます。」(参照ISTQB CT-AIシラバスv1.0、セクション9.4、99ページ中68ページ)

最新問題: 16

最初にツールによってラベル付けが行われ、次に人間によって検証または完了される 2 段階のプロセスを使用するデータラベル付けアプローチはどれですか。

4つの中から1つを選択してください

- A. 内部データラベル付け
- B. クラウドソーシングによるデータラベル付け
- C. アウトソーシングされたデータラベル付け
- D. AI支援によるデータラベリング

Answer: ([解答を表示する](#)**)**

ISTQB CT-AIシラバスのセクション2.4 「データラベリングアプローチ」では、AI支援によるデータラベリングを、自動化ツールが初期ラベリングを実行し、その後、人間のアンノテーターがラベルを検証、修正、または完成させるハイブリッドプロセスとして明確に定義しています。この2段階のプロセスにより、データ品質を確保するために人間の監視を維持しながら効率性が向上します。シラバスでは、この手法は、手動によるラベリングだけでは時間がかかりすぎる、またはコストがかかりすぎる場合、また、人間が最終的な正式なラベルを付与する前に、初期の自動化によって明らかなパターンを特定できる場合に効果的な妥協策であると説明されています。

オプションA (社内ラベリング)は、組織内のスタッフが実施するラベリングを指しますが、自動化は考慮されていません。オプションB (クラウドソーシングによるラベリング)は、分散した労働力を活用しますが、通常は自動化は行われません。オプションC (アウトソーシングによるラベリング)は、ラベリング作業を外部ベンダーに委託しますが、同様にAIファーストのステップは含まれ

ません。シラバスに記載されている、自動化と人的介入の2段階ワークフローは、オプションDのみに反映されています。

したがって、AI 支援によるデータラベル付け (オプション D) は間違いなく正しいと言えます。

有効な **CT-AI** 問題集は GoShiken.com が提供された合格しやすい CT-AI 試験問題集！

GoShiken.com が最新の **CT-AI** 試験問題集を提供しています。GoShiken.com CT-AI 試験問題は最新で、解答が正確でございます。最新の GoShiken.com CT-AI 問題集をゲットする人はこちら: <https://www.goshiken.com/ISTQB/CT-AI-mondaishu.html> (**12230%OFF**問題集溶と正解付きで **30%w** 特別割引コード: **Freepdfdumps**)

最新問題: 17

ソフトウェアコンポーネントは、機械学習を用いて手書きの数字をスキャンし、その数字を認識します。上記のシナリオにおいて、これはどのタイプの機械学習 (ML) の例ですか？

1つのオプションを選択

- A. 強化学習
- B. 回帰
- C. 分類
- D. クラスタリング

Answer: ([解答を表示する](#))

機械学習を用いて手書きの数字のスキャンから数字を認識することは、分類の一例です。その概要は次のとおりです。

分類: このタイプの機械学習では、入力データを定義済みのクラスに分類します。このシナリオでは、入力データ (手書きの数字) は10個の数字クラス (0~9) のいずれかに分類されます。

他の選択肢はなぜないのか:

強化学習: これは、目標を達成するために環境と対話することによって学習するものであり、数字を認識するという問題には当てはまりません。

回帰: これは、数字認識などの離散カテゴリではなく、連続した値を予測するために使用されます。

クラスタリング: 事前定義されたクラスを使用せずに類似のデータ ポイントをグループ化しますが、ここではそうではありません。

最新問題: 18

AI ベース システムのテスト環境の特性に関する正しい記述はどれですか。

4つの中から1つを選択してください

- A. 自律型 AI システムのテスト環境では、テストの設計と実行の両方を自律的に実行する必要があります。
- B. AI システムのテスト環境には、テスト オブジェクトの決定を説明できるツールが必要になる場合があります。

C. 自己学習型 AI システムのテスト環境は、テスト オブジェクトに適応し、テスト オブジェクトから学習する必要があります。

D. AI ベースのマルチエージェント システムのテスト環境は、決定論的に動作する必要があります。

Answer: (解答を表示する)

ISTQB CT-AIシラバス セクション4.3 AIシステムのテスト環境」)では、従来のソフトウェアテストとは異なり、AIシステムのテストでは、機械学習モデルの決定を分析および説明するための専用ツールが必要になる場合があると説明されています。これには、AIが特定の予測を行った理由を理解するための可視化ツール、説明可能性フレームワーク、診断ユーティリティが含まれます。AIの決定は不透明である可能性があるため、テスト環境は説明可能性をサポートし、オプションBが正しいことを確認する必要があります。

選択肢Aは不正解です。シラバスには、自律AIシステムに自律的なテスト環境が必要であるとは記載されていません。選択肢Cは不正解です。テスト環境は学習してはならず、予測不可能なテスト条件を回避するために安定した状態を維持する必要があります。選択肢Dは不正解です。マルチエージェントシステムでは確率的な相互作用が生じることが多く、決定論は必須ではなく現実的でもありません。

したがって、オプション B はシラバスに正確な選択肢となります。

最新問題: 19

次の特性のうち、AI システムの安全関連の問題を引き起こす可能性が最も低いのはどれですか？
1つのオプションを選択

- A. 非決定性
- B. 堅牢性
- C. 複雑度が高い
- D. 自己学習

Answer: B (メッセージを残す)

質問は、AIシステムの安全性に関する問題を引き起こす可能性が最も低い特性はどれか、というものです。それぞれの選択肢を評価してみましょう。

非決定性 (A): 非決定性システムでは、同じ入力であっても異なる結果が生成される可能性があります。予測できない動作や潜在的な安全上の問題につながる可能性があります。

堅牢性 (B): 堅牢性とは、システムがエラー、異常、予想しない入力を適切に処理する能力を指します。堅牢なシステムは、さまざまな条件下でも機能を維持できるため、安全性の問題が発生する可能性が低くなります。

高い複雑性 (C): AI システムの複雑さが高いと、システムの動作の理解、予測、管理が困難になり、安全性に関する問題が発生する可能性があります。

自己学習 (D) : 自己学習システムは新しいデータに基づいて適応するため、予期せぬ動作の変化を引き起こす可能性があります。適切に監視および制御されない場合、安全性の問題につながる可能性があります。

参照 :

ISTQB CT-AI シラバスのセクション 2.8 安全性と AI」では、AI システムの安全性に影響を与えるさまざまな要因について説明し、安全な運用を維持するための堅牢性の重要性を強調しています。

最新問題: 20

腐ったトマトを検出するために使用されるモデルをテストしたところ、一定数のトマトの画像に基づいて、テストエンジニアが次のデータを観察しました。

Confusion Matrix	Actually Rotten	Actually Fresh
Predicted Rotten	45	8
Predicted Fresh	5	42

この混同行列では、精度、再現率、特異度の値のどの組み合わせが正しいでしょうか？
1つのオプションを選択

- A. 0.87, 0.9, 0.84
- B. 1, 0.87, 0.84
- C. 1, 0.9, 0.8
- D. 0.84, 1, 0.9

Answer: [\(解答を表示する\)](#)

提供された混同行列から精度、再現率、特異度を計算するには、次の式を使用します。

* 混同マトリックス:

* 実際に腐っている: 45 (真陽性)、8 (偽陽性)

* 実際に新鮮: 5 (偽陰性)、42 (真陰性)

* 正確さ:

* 精度は、総母集団における真の結果 (真陽性と真陰性の両方) の割合です。

* 計算式: $\text{精度} = \frac{TP + TN}{TP + TN + FP + FN}$ 精度 = $\frac{TP + TN}{TP + TN + FP + FN}$

* 計算: 精度 = $\frac{45 + 42}{45 + 42 + 8 + 5} = \frac{87}{100} = 0.87$

* 再現率 (感度)

* リコールは、実際の陽性結果の合計に対する真陽性結果の割合です。

* 式: $\text{想起率} = \frac{TP}{TP + FN}$ 想起率 = $\frac{TP}{TP + FN}$

* 計算: 再現率 = $\frac{45}{45 + 5} = \frac{45}{50} = 0.9$

* 特異性:

* 特異度は、実際の陰性結果の合計に対する真陰性結果の割合です。

* 式: $\text{特異度} = \frac{TN}{TN + FP}$ 特異度 = $\frac{TN}{TN + FP}$

* 計算: 特異度 = $\frac{42}{42 + 8} = \frac{42}{50} = 0.84$

したがって、精度、再現率、特異度の正しい組み合わせはそれぞれ 0.87、0.9、0.84 です。

参考文献:

ISTQB CT-AI シラバスのセクション 5.1 混同マトリックス」では、精度、再現率、特異度などのさまざまなメトリックを計算するための詳細な式と説明が提供されています。

ML 機能パフォーマンス メトリクス」(ISTQB CT-AI シラバス、セクション 5)。

最新問題: 21

テスターは、データ ソース、取得、および前処理のレビューの一環として、システムの偏りをどのようにチェックできますか？

4つの中から1つを選択してください

A. レビュー中に、トレーニング データを取得するために使用された手順を分析することで、アルゴリズムの偏りを明らかにすることができます。

B. 前処理のレビュー中に、監査人は、サンプルの歪みにつながるような方法でデータが影響を受けているかどうかを明らかにすることができます。

C. 不適切なバイアスを検出するために、データ収集レビューの一環として LIME メソッドを使用する場合があります。

D. 前処理のレビューの一環として、データがアルゴリズムの偏りにつながるような影響を受けているかどうかを明らかにすることができます。

Answer: B ([メッセージを残す](#))

データレベルでのバイアス検出は、ISTQB CT-AIシラバスのセクション2.3 データ品質とバイアス」で説明されているように、データ取得および前処理手順をレビューすることで実行されます。サンプルバイアスは、データが歪んでいる場合、または前処理によって意図しない変化が生じた場合に発生します。例えば、フィルタリング、正規化、またはラベル付けの手順によってデータのサブセットに不均衡な影響が生じた場合などです。オプションBはこれを正しく反映しており、レビュー担当者は、前処理手順によってデータセットが変更され、サンプルの歪みが生じているかどうかを識別できます。これは、データパイプラインにおけるバイアス源のレビューに関するシラバスのガイダンスと完全に一致しています。

オプション A は不正解です。アルゴリズムの偏りはデータ収集手順ではなくモデルに由来するからです。

オプション C は、LIME がデータレビューではなくモデル後に適用される説明方法であるため、正しくありません。

オプション D では誤って 「アルゴリズムのバイアス」と記載されていますが、前処理はアルゴリズムのバイアスではなくサンプルのバイアスに影響します。

したがって、オプション B は、データ関連のレビュー中にバイアスを検出する方法に関するシラバスの定義に正しく一致しています。

最新問題: 22

ニューラル ネットワーク内のニューロンの活性化値出力は、ニューロンに計算を適用することによって得られます。

活性化値の計算に使用される入力を最もよく表すオプションは次のどれですか？

1つのオプションを選択

- A. ニューロン レベルでの個々のバイアス、前の層のニューロンの活性化値、およびニューロン間の接続に割り当てられた重み。
- B. 前の層のニューロンの活性化値と、ニューロン間の接続に割り当てられた重み。
- C. ニューロン レベルでの個々のバイアスと、ニューロン間の接続に割り当てられた重み。
- D. ニューロン レベルでの個々のバイアスと、前の層のニューロンの活性化値。

Answer: A (メッセージを残す)

ニューラルネットワークでは、ニューロンの活性化値は、前の層からの入力、接続の重み、そしてニューロンレベルのバイアスの組み合わせによって決定されます。詳細な内訳は以下のとおりです。

* アクティベーション値の入力:

* 前の層のニューロンの活性化値: これらは、現在のニューロンへの入力として機能する、前の層のニューロンからの出力です。

* 接続に割り当てられた重み: ニューロン間の各接続には重みが関連付けられており、入力信号の強度と方向を決定します。

* ニューロン レベルでの個別のバイアス: 各ニューロンには入力合計を調整するバイアス値があり、活性化関数をシフトできます。

* 計算:

* 活性化値は、前の層からの重み付けされた入力を合計し、バイアスを加えることによって計算されます。

* 式: $z = \sum (w_i \cdot a_i) + b$ 、ここで、 w_i は重み、 a_i は前のレイヤーからのアクティベーション値、 b はバイアスです。

* 次に、この合計に活性化関数 (シグモイド、ReLU など) を適用して、最終的な活性化値を取得します。

* オプションAが正しい理由:

* オプション A は、活性化値の計算に関係するすべてのコンポーネント (個々のバイアス、前のレイヤーの活性化値、および接続の重み) を正しく識別します。

* 他の選択肢を排除する:

* B. 前の層のニューロンの活性化値と、ニューロン間の接続に割り当てられた重み: このオプションでは、重要なバイアスが失われます。

* C. ニューロン レベルでの個々のバイアスと、ニューロン間の接続に割り当てられた重み: このオプションでは、前のレイヤーからのアクティベーション値が失われます。

* D. ニューロンレベルでの個々のバイアスと、前層のニューロンの活性化値
このオプションでは、重要な重みが考慮されません。

参考文献:

ISTQB CT-AI シラバスのセクション 6.1 「ニューラル ネットワーク」では、ニューラル ネットワーク内のニューロンのコンポーネントと機能について説明します。

「ニューラル ネットワークの活性化関数」(ISTQB CT-AI シラバス、セクション 6.1.1)。

最新問題: 23

モデルとアルゴリズムのハイパーパラメータを設定するための ML ワークフローの最も適切な段階は次のうちどれですか。

1つのオプションを選択

- A. モデルの評価
- B. モデルのデプロイ
- C. モデルの調整
- D. データテスト

Answer: C ([メッセージを残す](#))

モデルとアルゴリズムのハイパーパラメータの設定は、機械学習ワークフローの重要なステップであり、主にチューニングフェーズで行われます。

モデルの評価 (A): この段階では、メトリックを使用してモデルのパフォーマンスを評価しますが、通常はハイパーパラメータの設定は含まれません。

モデルのデプロイ (B): デプロイは、モデルを本番環境に導入し、実際のアプリケーションで使用する段階です。この段階の前に、ハイパーパラメータはすでに設定されている必要があります。

モデルのチューニング (C): これはハイパーパラメータを設定する適切な段階です。チューニングとは、モデルのパフォーマンスを最適化するためにハイパーパラメータを調整することです。

データテスト (D): データテストでは、モデルのトレーニングとテストに使用されるデータの品質と整合性を確認します。ハイパーパラメータの設定は含まれません。

したがって、モデルとアルゴリズムのハイパーパラメータを設定するための ML ワークフローの最も適切な段階は、C. モデルの調整です。

参照:

ISTQB CT-AI シラバスのセクション 3.2 の ML ワークフローでは、ハイパーパラメータを設定するチューニングフェーズを含む、ML プロセスのさまざまな段階について概説しています。

サンプル試験問題ドキュメントの質問 #31 では、ハイパーパラメータが設定される ML ワークフローの段階について具体的に説明しています。

最新問題: 24

次のオプションのうち、クラスタリングを最もよく表しているのはどれですか？

1つのオプションを選択

- A. クラスタリングは連続量の分類です。
- B. クラスタリングは教師あり学習です。
- C. 出力クラスに関する事前の知識なしでクラスタリングが実行されます。
- D. クラスタリングを行うには、クラスを知っておく必要があります。

Answer: C ([メッセージを残す](#))

クラスタリングは、類似したデータポイントをクラスターにグループ化する機械学習手法の一種です。教師なし学習において重要な概念であり、出力クラスに関する事前知識なしにデータ内のパターンやグループ分けを見つけようとするアルゴリズムです。それぞれのオプションを分析してみましょう。

A. クラスタリングは連続量の分類です。

これは誤りです。分類は通常、離散的なカテゴリを対象としますが、クラスタリングは類似したデータポイントをグループ化するものです。連続量の分類は、一般的に回帰と呼ばれます。

B. クラスタリングは教師あり学習です。

これは不正解です。クラスタリングはラベル付きデータに依存しないため、教師なし学習手法です。

C. クラスタリングは出力クラスに関する事前知識なしで実行されます。

正解です。クラスタリングでは、アルゴリズムはクラスに関する事前知識なしにデータポイントをクラスターにグループ化します。そして、データに内在する構造を発見します。

D. クラスタリングを行うには、クラスを知っておく必要があります。

これは誤りです。クラスタリングではクラスに関する事前知識は必要ありません。むしろ、データ自体に基づいてクラスまたはグループを識別し、形成することを目的としています。

したがって、クラスタリングは出力クラスに関する事前の知識なしで実行される教師なし学習手法であるため、正解はCです。

最新問題: 25

AI ベースのシステムのどのような特性により、安全性（人間に危害を加えないことなど）を確保することが困難になるのでしょうか。

4つの中から1つを選択してください

A. 決定論

B. 複雑さ

C. 解釈可能性

D. 堅牢性

Answer: B (メッセージを残す)

ISTQB CT-AIシラバスには、AIベースのシステムの安全性確保を困難にするいくつかの特性が列挙されています。セクション2.8「安全性とAI」では、安全性の確保を困難にする特性が明確に挙げられています。

複雑性、非決定性、確率的動作、自己学習、透明性の欠如、そして堅牢性の欠如。これらのうち、複雑性は主要な課題です。なぜなら、現代のAIシステム、特にディープラーニングを使用するシステムは、高度に非線形な動作、多数のパラメータ、そして予測困難な複雑な相互作用を備えているからです。

オプションB（複雑性）はシラバスと直接一致しているため正解です。

オプションA（決定論はAIの振る舞いとは正反対です。AIは多くの場合非決定論的であり、決定論はシステムを安全でないものにするわけではありません。オプションC（解釈可能性は信頼性と説明可能性に影響を与えますが、シラバスでは透明性の課題として位置付けられており、安全性確保における主要な難点ではありません。オプションD（堅牢性は望ましい特性であり、安全性確保が難しい理由ではありません。堅牢性の欠如が課題となるのであって、堅牢性そのものではありません。

したがって、複雑さはシラバスの明示的な安全関連の難しさを最もよく反映します。

最新問題: 26

AIベースのシステムの学習に使用されたトレーニングデータにアクセスできます。この情報を確認し、テスト作成時のガイドラインとして使用できます。これはどのような特性ですか？

- A. 自律性
- B. 探索可能性
- C. 透明性
- D. アクセシビリティ

Answer: C (メッセージを残す)

AI ベースのシステムは、内部の意思決定プロセスが不明確なブラックボックスのように動作することがあります。透明性とは、AI システムのトレーニング データ、アルゴリズム、意思決定プロセスを検査して理解する能力を指します。

* 透明性により、テスターと関係者は AI システムがどのようにトレーニングされたかを確認できます。

* トレーニング データへのアクセスは、テスターがデータセットの偏り、完全性、代表性を分析できるため、透明性の重要な要素となります。

* 透明性は、説明可能な AI (XAI) の重要な特性です。

* トレーニング データにアクセスできるということは、テスターがデータが AI の動作にどのように影響するかを調査できることを意味します。

* AI の規制および倫理ガイドラインでは透明性が重視されています。

* GDPR や信頼できる AI ガイドラインなどの多くの AI 倫理フレームワークでは、公正かつ説明可能な AI 意思決定を確保するために透明性を推奨しています。

* (A) 自律性#

* 自律性とは、AIシステムが人間の介入なしに自律的に意思決定を行う能力を指します。ただし、学習データへのアクセスは自律性とは関係ありません。自律性とは、人間の制御なしに自己学習と意思決定を行うことを指します。

* (B) 探索可能性#

* 探索可能性とは、AI システムをインタラクティブにテストしてその動作を理解する能力を指しますが、トレーニング データへのアクセスとは直接関係しません。

* (D) アクセシビリティ#

* アクセシビリティとは、トレーニング データを検査する機能ではなく、システムの使いやすさを指します。

* 透明性とは、モデルを生成するために使用されるトレーニング データとアルゴリズムが理解しやすいことです。透明性: これは、モデルを生成するために使用されるアルゴリズムとトレーニング データを容易に判断できることを意味します。」オプション C が正しいのはなぜですか?他のオプションが間違っているのはなぜですか?ISTQB 認定テスターの AI テスト学習ガイドからの参照したがって、透明性にはトレーニング データへのアクセスが含まれ、テスターが AI の意思決定プロセスを理解できるため、オプション C が正解です。

最新問題: 27

ニューラル ネットワークの構造と機能に関する次の記述のうち正しいものはどれですか。
4つの中から1つを選択してください

- A. ニューロンのバイアスはその前の層のニューロンの活性化値によって決定される。
- B. ニューラルネットワークのトレーニングでは、ニューロン間の接続における重みの値のみが変化します。
- C. 単層パーセプトロンはニューラルネットワークではない
- D. ディープニューラルネットワークの入力層には、出力層と同じ数のニューロンが必要です。

Answer: (解答を表示する)

ISTQB CT-AIシラバスのセクション1.7 「ニューラルネットワーク」では、ニューラルネットワークは重み付きリンクで接続されたニューロンで構成されると説明されています。学習中は、これらの接続の重みを調整することで学習が行われます。これが勾配降下法とバックプロパゲーションの本質です。選択肢Bはこの動作を正しく述べています。重みのみを変更され、活性化関数、ニューロン数、アーキテクチャ構造は変更されません。

選択肢Aは不正解です。ニューロンのバイアスは以前の活性化によって決定されるものではなく、重み付けされた入力の合計に追加される独立した学習可能なパラメータです。選択肢Cは不正解です。シラバスでは単層パーセプトロンはニューラルネットワークの一種として有効ですが、線形分離可能な問題に限定されると述べられています。

選択肢Dは不正解です。入力ニューロンの数が出力ニューロンの数以上である必要があるという規則はありません。入力ニューロンは特徴の数に対応し、出力ニューロンはタスクまたはクラスに対応します。

したがって、オプション B は、ニューラル ネットワークのトレーニング中に何が変わるかに関するシラバスの定義を正確に反映しています。

最新問題: 28

ペアワイズテストは、自動運転車の状況において、パラメータの組み合わせの数の爆発的な増加を制御するために使用できます。

次のオプションのうち、この驚異的なパラメータの増加の理由となる可能性が最も低いのはどれですか？

1つのオプションを選択

- A. さまざまな道路の種類
- B. さまざまな気象条件
- C. 機能パフォーマンスを評価するためのMLモデルメトリクス
- D. ADAS、車線変更支援などのさまざまな機能。

Answer: C (メッセージを残す)

ペアワイズ検定は、自動運転車のような複雑なシステムで発生する可能性のある、多数のパラメータの組み合わせを処理するために使用されます。与えられた選択肢のうち、パラメータ数の爆発的な増加の原因となる可能性が最も低いのはどれか、という問いです。

多様な道路タイプ A) : 自動運転車、高速道路、市街地、地方道路など、様々な道路タイプを走行する必要があります。道路タイプによって特性が異なるため、車両のシステムは様々なシナリオに適応し、対応する必要があります。そのため、これはパラメータの進化に大きく貢献する要因です。

様々な気象条件 B) : 雨、雪、霧、強い日差しといった気象条件は、自動運転車の性能に大きな影響を与えます。車のセンサーとアルゴリズムはこれらの変化する条件に適応する必要があります、考慮すべきパラメータの数が増えます。

機能パフォーマンスを評価するための機械学習 (ML) モデルメトリクス C) : 機械学習(ML)モデルのパフォーマンス評価は重要ですが、道路の種類、気象条件、車両の特徴のように、パラメータの組み合わせの爆発的な増加に直接寄与するわけではありません。メトリクスはパフォーマンスを測定および評価するために使用されますが、システムが処理しなければならない可変条件そのものではありません。

ADAS、レーンチェンジアシストなどの様々な機能 D) : 先進運転支援システム (ADAS)などの機能は、自動運転車の複雑さを増します。各機能には複数の設定や動作モードがあり、パラメータの総数が増加します。

したがって、パラメータ数が驚異的に増加した理由として最も考えにくいのは、機能パフォーマンスを評価するための C. ML モデル メトリックです。

参照 :

ISTQB CT-AI シラバスのセクション 9.2 「ペアワイズ テスト」では、自動運転車で使用されるものを含む AI ベースのシステムにおけるさまざまな変数の組み合わせを管理するためのこの手法の適用について説明しています。

サンプル試験問題ドキュメントの質問 #29 では、自動運転車におけるパラメータの組み合わせの爆発的な増加の背景を説明し、この複雑さを管理する方法としてペアワイズ テストの使用を強調しています。

最新問題: 29

次の特性のうち、AI システムの安全関連の問題を引き起こす可能性が最も低いのはどれですか？
1つのオプションを選択

- A. 非決定性
- B. 堅牢性
- C. 複雑度が高い
- D. 自己学習

Answer: B (メッセージを残す)

質問は、AIシステムの安全性に関する問題を引き起こす可能性が最も低い特性はどれか、というものです。それぞれの選択肢を評価してみましょう。

* 非決定性 (A): 非決定性システムでは、同じ入力であっても異なる結果が生成される可能性があり、予測できない動作や潜在的な安全上の問題につながる可能性があります。

* 堅牢性 (B): 堅牢性とは、システムがエラー、異常、予期しない入力を適切に処理する能力を指します。堅牢なシステムは、さまざまな条件下でも機能を維持できるため、安全性の問題が発生する可能性が低くなります。

* 複雑性が高い (C): AI システムの複雑性が高いと、システムの動作の理解、予測、管理が困難になり、安全性に関する問題が発生する可能性があります。

* 自己学習 (D) : 自己学習システムは新しいデータに基づいて適応するため、予期せぬ動作の変化を引き起こす可能性があります。適切に監視および制御されない場合、安全性の問題につながる可能性があります。

:

ISTQB CT-AI シラバスのセクション 2.8 安全性と AI」では、AI システムの安全性に影響を与えるさまざまな要因について説明し、安全な運用を維持するための堅牢性の重要性を強調しています。

最新問題: 30

次のどれが、教師なし学習によって解決できるクラスタリング問題の例ですか？

- A. 買い物客とその買い物傾向を関連付ける
- B. ひれの種類に基づいて個々の魚をグループ化する
- C. パッケージの魅力に基づいてマフィンの購入を分類する
- D. 特に成功した広告キャンペーン後のキャットフードの予想購入量を推定する

Answer: A ([メッセージを残す](#))

シラバスではクラスタリングを次のように定義しています。

クラスタリング：入力データポイントの類似点を特定し、共通の特性や属性に基づいてグループ化することが求められる問題です。例えば、クラスタリングはマーケティングを目的として、異なるタイプの顧客を分類するために使用されます。（参照ISTQB CT-AIシラバスv1.0、セクション 3.1.2、99ページ中26ページ）

最新問題: 31

次の特性のうち、AI システムの安全関連の問題を引き起こす可能性が最も低いのはどれですか？

1つのオプションを選択

- A. 非決定性
- B. 堅牢性
- C. 複雑度が高い
- D. 自己学習

Answer: B ([メッセージを残す](#))

質問は、AIシステムの安全性に関する問題を引き起こす可能性が最も低い特性はどれか、というものです。それぞれの選択肢を評価してみましょう。

* 非決定性 (A): 非決定性システムでは、同じ入力であっても異なる結果が生成される可能性があります。予測できない動作や潜在的な安全上の問題につながる可能性があります。

* 堅牢性 (B): 堅牢性とは、システムがエラー、異常、予期しない入力を適切に処理する能力を指します。堅牢なシステムは、さまざまな条件下でも機能を維持できるため、安全性の問題が発生する可能性が低くなります。

* 複雑性が高い (C): AI システムの複雑性が高いと、システムの動作の理解、予測、管理が困難になり、安全性に関する問題が発生する可能性があります。

* 自己学習 (D) : 自己学習システムは新しいデータに基づいて適応するため、予期せぬ動作の変化を引き起こす可能性があります。適切に監視および制御されない場合、安全性の問題につながる可能性があります。

参考文献:

* ISTQB CT-AI シラバスのセクション 2.8 安全性と AI」では、AI システムの安全性に影響を与えるさまざまな要因について説明し、安全な運用を維持するための堅牢性の重要性を強調しています。

有効な **CT-AI** 問題集は GoShiken.com が提供された合格しやすい CT-AI 試験問題集！

GoShiken.com が最新の **CT-AI** 試験問題集を提供しています。GoShiken.com CT-AI 試験問題は最新で、解答が正確でございます。最新の GoShiken.com CT-AI 問題集をゲットする人はこちら: <https://www.goshiken.com/ISTQB/CT-AI-mondaishu.html> (**12230%OFF**問題集溶と正解付きで **30%w** 特別割引コード: **Freepdfdumps**)

最新問題: 32

あるワープロ会社が自動テキスト修正ツールを開発しています。自動テキスト修正機能の開発には機械学習アルゴリズムが使用されました。テスターは、入力を開始すると

「ワイト島」は「八島」に置き換えられます。UATテスターの中には、この変更に気づかずに受け入れてしまった人もいます。

これはどのような種類の偏見ですか？

- A. 地理的/地域
- B. 自動化/自己満足
- C. 自己満足/無視
- D. 無知/認知

Answer: (解答を表示する)

シラバスでは自動化バイアスを次のように説明しています。

「人が他の情報源よりも自動化された意思決定システムの推奨を優先することで生じるバイアスの一種。」これは自己満足バイアスとも呼ばれ、テスターが自動化システムの出力を疑問視することなく受け入れてしまう現象です。

(参照ISTQB CT-AIシラバスv1.0、用語集、99ページ中89ページ)

最新問題: 33

次のオプションのうち、ML システムでテストデータを取得する際の課題を説明していないものはどれですか。

1つのオプションを選択

- A. コンプライアンス上、入力された個人データには適切な注意を払う必要があります。
- B. データの性質は時間とともに常に変化します。
- C. ユースケースのデータが急速に生成されています。
- D. 公開ソースから取得されるテストデータ。

Answer: C (メッセージを残す)

* MLシステムにおけるテストデータ取得の課題 :コンプライアンス要件、時間の経過に伴うデータの性質の変化、そして公開ソースからのデータの取得は、大きな課題です。データが迅速に生成されることは、一般的には課題ではありません。むしろ、トレーニングとテストのためのデータ量が増えるため、メリットとなることもあります。

* 参考: ISTQB_CT-AI_Syllabus_v1.0、データ準備とデータ品質の問題に関するセクション。

最新問題: 34

AllerEgo社は、様々な地形や敵機編隊といった戦闘状況下におけるパイロットの行動を、自己学習を用いて予測する製品です。訓練後、モデルを実世界のデータに曝露したところ、モデルの挙動が不良であることが判明しました。訓練とテストに適した状態にするために、データに対して多数のデータ品質テストが実施されました。

特に AI システムの自己学習の性質を考慮すると、次のオプションのうち、パフォーマンスの低下の考えられる理由として最も適切ではないものはどれですか。

1つのオプションを選択

モデルが受け入れられる前に改善の基準を定義することが難しい。

変化のペースが速かったため、テストに十分な時間が取れませんでした。

動作環境の性質が不明であり、仕様が不十分なためにパフォーマンスが低下した可能性があります。

AI システムにはアルゴリズムの偏りがありました。

A. モデルが受け入れられる前に改善の基準を定義することが難しい。

AIモデルの受け入れにおいては、改善基準の定義が課題となりますが、これは実世界のシナリオにおけるパフォーマンスの低下とは直接関係しません。これは、導入後のモデルのリアルタイムパフォーマンスに影響を与えるというよりも、評価と導入段階に関するものです。

B. 変化のペースが速かったため、テストに十分な時間が取れませんでした。

これはモデルのパフォーマンスに大きな影響を与える可能性があります。システムが自己学習型の場合、迅速な適応が求められ、テスト時間が不十分だと学習が不完全になり、パフォーマンスが低下する可能性があります。

C. 動作環境の性質が不明であり、仕様が不十分なためにパフォーマンスが低下した可能性があります。

これはパフォーマンスに影響を及ぼす可能性が非常に高いです。自己学習型AIシステムは、効果的に適応 学習するために、動作環境の詳細な仕様を必要とします。環境の仕様が不十分な場合、モデルは現実世界のシナリオにおいて正確に動作しない可能性があります。

D. AIシステムにアルゴリズムのバイアスがありました。アルゴリズムのバイアスはAIシステムのパフォーマンスに重大な影響を与える可能性があります。モデルにバイアスがある場合、さまざまなシナリオやデータ分布において良好なパフォーマンスが得られません。

Answer: A ([メッセージを残す](#))

自己学習の性質とリアルタイムの適応性の必要性を考慮すると、オプション A はリアルタイムのパフォーマンスの問題ではなく受け入れ基準を扱うため、パフォーマンスの低下を説明する可能性は最も低くなります。

最新問題: 35

次のテストのうち、ML モデルのテスト フェーズで実行される可能性が最も低いのはどれですか。1つのオプションを選択

- A.** 分類モデルの精度をテストします。
- B.** ML モデルを活用したサービスの API をテストします。
- C.** モデルのトレーニング速度をテストします。
- D.** モデルによる予測の速度をテストします。

Answer: C ([メッセージを残す](#))

質問は、MLモデルのテストフェーズで実行される可能性が最も低いテストはどれか、というものです。それぞれの選択肢について考えてみましょう。

* 分類モデルの精度テスト (A): 精度テストは、MLモデルテストフェーズの基本的な部分です。モデルが意図したとおりにデータを正しく分類し、必要なパフォーマンス指標を満たしていることを確認します。

* MLモデルを活用したサービスのAPIテスト (B) APIテストは、特にMLモデルがサービスの一部としてデプロイされている場合に重要です。これにより、サービスが他のシステムと適切に統合され、APIが期待どおりに動作することが保証されます。

* モデルの学習速度のテスト (C): これはMLモデルのテストフェーズに含まれる可能性が最も低いです。学習速度は、モデルの最適化とチューニングを行う開発フェーズにおいてより重要になります。テストでは、学習速度よりも、モデルのパフォーマンスと動作に重点が置かれます。

* モデルによる予測速度のテスト (D): 予測速度のテストは、モデルが実稼働環境、特にリアルタイムアプリケーションのパフォーマンス要件を満たしていることを確認するために重要です。

:

ISTQB CT-AI シラバスのセクション 3.2 「ML ワークフロー」とセクション 5 「ML 機能パフォーマンス メトリック」では、モデル テスト フェーズでのテストの焦点について説明しています。これには精度と予測速度が含まれますが、トレーニング速度は含まれません。

最新問題: 36

次のニューラル ネットワーク カバレッジ基準のうち、どれがそのアプリケーションに適応できますか？

4つの中から1つを選択してください

- A. サイン・サイン・カバレッジ
- B. 符号変化カバレッジ
- C. 閾値カバレッジ
- D. ニューロンカバレッジ

Answer: ([解答を表示する](#))

ISTQB CT-AIシラバスのセクション4.2 AIモデルのテストカバレッジ基準」では、ニューラルネットワークに特化したカバレッジ手法について説明しています。これらの手法の中で、閾値カバレッジは適応可能と明記されており、テスト担当者はニューロンの活性化を考慮するかどうかを決定するために異なる閾値を選択できます。

カバレッジされます。」この柔軟性により、モデル アーキテクチャ、問題領域、および必要なテストの徹底度に応じてしきい値カバレッジを調整できます。

オプションAとB (Sign-SignとSign-Changeのカバレッジ)はより厳格な構造基準であり、シラバス内では適応可能とはされていません。これらはニューロン活性化の符号パターンに焦点を当てており、閾値の変更は認められていません。オプションD (ニューロンカバレッジ)は、少なくとも1回活性化したニューロンの割合を測定します。

シンプルですが、適応性の高い基準として定義されていません。その限界は文書化されており、浅い洞察しか提供せず、高いカバレッジを容易に達成してしまいます。

しきい値カバレッジのみで、テスターはアクティベーションしきい値を調整してより精密なカバレッジ測定を行うことができるため、オプション C が適切な選択となります。

最新問題: 37

AIを用いて適切な運転行動と反応を決定する自動運転車をテストしています。テスト対象のパラメータと組み合わせを評価した結果、制限時間内にテストするには数が多すぎると判断しました。パラメータを制限するためにペアワイズテストを使用することを提案されました。テスト対象ソフトウェアの複雑さを考慮すると、ペアワイズテストを使用することでどのような結果が得られる可能性がありますか？

- A. テストするパラメータの数を 12 個未満に減らすことができます。
- B. 優先度の高い欠陥はすべてこの方法を使用して識別されます。
- C. 必要なテストの数は減らすことができますが、すべてのテストを実行するには自動化が必要になるほどテストのセットが大量にある場合があります。
- D. AI が関係しており、進化する値によって検証できない予期しない結果が生じる可能性があるため、この問題にはペアワイズを適用できません。

Answer: ([解答を表示する](#))

ペアワイズテストは、すべての可能な組み合わせではなく、パラメータのペア間の相互作用をテストすることに焦点を当てることで、テストケース数を削減する組み合わせテスト手法です。入

カパラメータの組み合わせが非常に多くなる可能性がある自動運転車などのAIベースのシステムで広く使用されています。

* オプション A: テストするパラメータの数を 12 個未満に減らすことができます。」

* これは誤りです。ペアワイズテストはテストケースの数を大幅に削減しますが、必ずしも12個などの固定数に限定されるわけではありません。最終的なテスト数は、パラメータの数とその取り得る値によって異なります。

* オプション B: この方法を使用して、優先度の高い欠陥がすべて特定されます。」

* これは誤りです。ペアワイズテストは2つのパラメータ間の相互作用によって生じる欠陥の検出には効果的ですが、3つ以上のパラメータを含むより複雑な相互作用によって生じる欠陥は検出できない可能性があります。

* オプション C: 必要なテストの数は減らせますが、すべてのテストを実行するには自動化が必要になるほどテストのセットが大量にある可能性があります。」

* 正解です。ペアワイズテストによってテストケースの数は削減されますが、自動運転車などのAIベースのシステムでは依然として多数のテストシナリオが存在します。そのため、すべてのテストケースを限られた時間内に実行するには、自動化が必要になることがよくあります。

* オプション D: この問題には AI が関係しているため、ペアワイズを適用することはできません。また、進化する値によって、検証できない予期しない結果が生じる可能性があります。」

* これは誤りです。ペアワイズテストは、時間の経過とともに進化するシステムも含め、AIベースのシステムに適用できます。ただし、進化する動作を検証するには、追加のテスト手法が必要になる場合があります。

* AI システムのペアワイズ テスト: ペアワイズ テストは、欠陥検出機能を維持しながらテストケースの数を効果的に削減できるため、広く使用されています。」

* 自動化の要件: 実際には、ペアワイズ テストの場合でも、広範なテスト スイートでは自動化が必要になる場合があります」。

回答オプションの分析:ISTQB CT-AIシラバス参照:

最新問題: 38

次のどれが、教師なし学習によって解決できるクラスタリング問題の例ですか？

A. 買い物客とその買い物傾向を関連付ける

B. ひれの種類に基づいて個々の魚をグループ化する

C. パッケージの魅力に基づいてマフィンの購入を分類する

D. 特に成功した広告キャンペーン後のキャットフードの予想購入量を推定する

Answer: A ([メッセージを残す](#))

クラスタリングは教師なし学習の一種で、事前定義されたラベルを使わずに類似性に基づいてデータポイントをグループ化します。ISTQB CT-AIシラバスによると、クラスタリングは次のようなシナリオで使用されます。

* 目的は、データ内の自然なグループ化を見つけることです。

* データセットにはラベル付けされた出力がありません。

* パターンと構造は自動的に識別される必要があります。

回答の選択肢を分析する:

- * A. 買い物客とその買い物傾向を関連付ける # 正解
 - * 買い物客は、購買行動（高級品を求める買い物客と予算重視の買い物客など）に基づいてグループ化できます。これは、市場セグメンテーションにおける一般的なクラスタリングアプリケーションです。
 - * B. ひれの種類に基づいて個々の魚をグループ化する # 偽
 - * ひれの種類にラベルが付けられている場合は、分類問題となり、教師あり学習が必要になります。
 - * C. パッケージの魅力に基づいてマフィンの購入を分類する # 偽
 - * 魅力スコアまたはラベルを事前に定義する必要があるため、クラスタリングではなく分類です。
 - * D. 広告キャンペーン後のキャットフードの予想購入量の推定 # 不正解
 - * これは予測タスクであり、教師あり学習の一部である回帰モデルに最適です。
- したがって、クラスタリングは事前定義されたラベルなしで傾向に基づいて買い物客をグループ化するために使用されるため、オプション A が最適な回答です。

認定テスター AI テスト学習ガイド 参考文献:

- * ISTQB CT-AI シラバス v1.0、セクション 3.1.2 (教師なし学習 - クラスタリングと関連付け)
- * ISTQB CT-AI シラバス v1.0、セクション 3.3 (ML の形式の選択 - クラスタリング)。

最新問題: 39

次のテストのうち、ML パイプラインでさまざまな種類のバイアスを検出するのに役立つテストを最もよく表しているのはどれですか。

1つのオプションを選択

- A. トレーニング データ内の分布シフトに不適切なバイアスがないかテストします。
- B. モデル評価中にデータのバイアスについてモデルをテストします。
- C. アルゴリズムの偏りのソースについてデータ パイプラインをテストします。
- D. 入力テスト データに潜在的なサンプル バイアスがないか確認します。

Answer: B (メッセージを残す)

ML パイプラインのバイアス検出には、ML プロセス全体の公平性と正確性を確保するためのさまざまなテストが含まれます。

訓練データにおける分布のシフトを検証し、不適切なバイアスの有無を確認する A) これは、モデルのバイアスにつながる可能性のあるデータ分布のシフトの有無を確認することを意味します。これは重要なテストですが、バイアスを検出するための最も直接的な方法ではありません。モデル評価中にデータバイアスをテストする B) これは、モデルを評価し、トレーニングに使用したデータにバイアスがないか検出する重要な段階です。これにより、モデルに潜在するデータバイアスに直接対処します。

データパイプラインにおけるアルゴリズムバイアスの発生源のテスト C) このテストは、パイプライン内のデータ処理および変換段階から発生する可能性のあるバイアスを特定するのに役立つため、非常に重要です。アルゴリズムバイアスの発生源を検出することで、モデルがこれらのプロセスからバイアスを継承しないようにすることができます。

入力テスト データに潜在的なサンプル バイアスがないか確認します (D): これは重要なステップですが、全体的なデータ パイプラインよりも入力データに重点が置かれます。

したがって、ML パイプラインでさまざまな種類のバイアスを検出するのに役立つ最も有用なテストは、B です。モデル評価中にデータ バイアスについてモデルをテストします。

参照：

ISTQB CT-AI シラバスのセクション 8.3 「アルゴリズム、サンプル、不適切なバイアスのテスト」では、ML パイプラインのさまざまな段階でバイアスを検出するために実行できるさまざまなテストについて説明します。

サンプル試験問題ドキュメントの質問 #32 では、モデルのバイアス評価の重要性が強調されています。

最新問題: 40

トレーニング、検証、およびテスト データ セットの使用に関する正しい記述はどれですか。

4つの中から1つを選択してください

A. 利用できるデータが限られている場合は、トレーニング中に検証データ セットとテスト データ セットを複数の方法で組み合わせることができます。

B. 利用できるデータが限られている場合は、別のテスト データ セットを使用せずに作業する方がよい場合があります。

C. 最適な方法は、データをトレーニング データ セット、検証データ セット、テスト データ セット間で均等に分散することです。

D. テスト データ セット内のデータは、トレーニング データ セット内のデータおよび検証データ セット内のデータと同等である必要があります。

Answer: D ([メッセージを残す](#))

ISTQB CT-AIシラバス セクション3.2 「モデル評価」では、学習データセット、検証データセット、テストデータセットの正しい使用方法が規定されています。テストデータセットは実際の運用データを代表するものでなければならず、学習データセットと検証データセットと分布が等しく、公平で偏りのない評価を保証する必要があることが強調されています。オプションDはまさにこの要件に合致しています。

選択肢Aはシラバスに矛盾しています。検証セットとテストセットの目的が異なっているためです。検証セットはチューニング用、テストセットは最終評価用です。これらを組み合わせると、結果の信頼性が損なわれます。選択肢Bは誤りです。シラバスでは、データが限られている場合でも、テストセットを省略するのではなく、テストセットを維持するか、クロスバリデーションなどの手法を使用することが推奨されています。選択肢Cは誤りです。均等配分 (33/33/33)は推奨されません。通常、トレーニングセットははるかに大きい (例70~80%)ためです。

したがって、OptionD はシラバスのガイダンスに沿った唯一のステートメントです。

最新問題: 41

報告された欠陥を AI を使用して分析することに関する最も正しい記述はどれですか？

4つの中から1つを選択してください

- A. 重大な欠陥チケットでトレーニングされた ML モデルは、深刻な結果を引き起こす欠陥を識別できます。
- B. ML モデルは、欠陥の重大性をチェックするときに重複した欠陥の識別をサポートできます。
- C. ML モデルは、割り当て中に報告された欠陥のカテゴリを識別できます。
- D. ML モデルは、チケットの内容に基づいて欠陥を処理する必要がある開発者を識別します。

Answer: C ([メッセージを残す](#))

ISTQB CT-AIシラバス セクション5.3 欠陥分析のためのAIサポート」)では、AIは自然言語処理または分類モデルを用いて欠陥レポートを分類できると説明されています。分類は、欠陥を効率的にルーティングし、システムのどの領域が影響を受けているかを特定するのに役立ちます。したがって、選択肢Cは正解です。AIは欠陥カテゴリを識別し、割り当てとトリアージを支援できます。選択肢Aは不正解です。機械学習はドメイン固有のリスクモデリングなしには重大度や結果を推測できません。選択肢Bは重複検出と重大度を不正確に結び付けています。シラバスでは重複検出と重大度分析を区別しています。選択肢Dは不正解です。AIはカテゴリを用いて欠陥のルーティングを支援する可能性があります、シラバスではAIが特定の開発者を特定するとは述べられていません。

したがって、オプション C はシラバスに正確な記述です。

最新問題: 42

コロンビアのあるコーヒー生産地域では、激しい嵐がいくつか発生し、生産量に大きな損失が生じました。これにより、コーヒーの株価は大幅に下落しました。

上記のような現象がコーヒー株価に与える影響を検出するために、株価予測の機械学習モデルで実行する必要があるテストは次のうちどれですか。

1つのオプションを選択

- A. 精度のテスト
- B. バイアスのテスト
- C. コンセプトドリフトのテスト
- D. セキュリティのテスト

Answer: ([解答を表示する](#)**)**

* 株価予測モデルのテストの種類 :コンセプトドリフトとは、対象変数の統計特性が時間の経過とともに変化することを指します。コーヒー生産に甚大な損失をもたらし、株価に影響を与えるような激しい暴風雨が発生した場合、モデルが時間の経過とともにデータの新しいパターンに適応できることを確認するために、コンセプトドリフトのテストが必要になります。

* 参照: ISTQB_CT-AI_Syllabus_v1.0、セクション 7.6 コンセプト ドリフトのテスト」では、変化する外部要因の影響を受ける可能性のあるモデルにおけるコンセプト ドリフトをテストする必要性について説明しています。

最新問題: 43

ニューラルネットワークを使って、ロボット掃除機が物体にぶつからずに走行できるように学習させています。速度を上げることを奨励し、バンパーセンサーにぶつからないようにする報酬ス

キームを設定しました。すると、予想に反して、掃除機は後進するように学習してしまいました。これは、背面にバンパーがないためです。これはどのような種類の行動の例ですか？

- A. エラー短絡
- B. 報酬ハッキング
- C. 透明性
- D. 解釈可能性

Answer: B (メッセージを残す)

シラバスでは報酬ハッキングを次のように定義しています。

報酬ハッキングは、AIベースのシステムが、設計者の意図を歪めた『巧みな』あるいは『簡単な』解決策を用いて特定の目標を達成することで発生する可能性があります。」この場合、掃除機は報酬関数の抜け穴、つまりバンパートリガーを回避するために後進しながら速度に対する報酬を最大化するという抜け穴を発見しました。

(参照ISTQB CT-AIシラバスv1.0、セクション2.6、99ページ中24ページ)

最新問題: 44

ある銀行は、どの申請者に融資を行うべきかを決定するアルゴリズムを利用したいと考えています。銀行はデータサイエンティストを雇用し、申請者が融資を返済するかどうかを予測するロジスティック回帰モデルを構築します。

銀行は過去の顧客に関する十分なデータを持っており、そのデータをトレーニングデータセットとテストデータセットにランダムに分割する。

/検証データセット。以下の独立変数を用いて、トレーニングデータセット上にロジスティック回帰モデルを構築します。

性別

配偶者の有無

扶養家族の数

教育

所得

融資額

ローン期間

信用スコア

このモデルは、信用スコアが高く、総所得が多い人ほどローンを返済する可能性が高いことを示しています。データサイエンティストは、他の銀行向けに作成された過去のモデルに基づき、このモデルにバイアスが存在する可能性があるとし唆しています。

この情報を考慮すると、モデルの潜在的なバイアスをチェックするための最適なテスト方法は何でしょうか？

A. トレーニング データ セットが運用上適切であることを確認するには、経験に基づくテストを使用する必要があります。

これには、トレーニング データ セット内のバイアスをチェックするための探索的データ分析 (EDA) の適用が含まれます。

- B.** トレーニング データ セットを使用して作成されたモデルとテスト データ セットを使用して作成された別のモデルを比較するには、バックツーバック テストを使用する必要があります。2 つのモデルが大幅に異なる場合は、元のモデルにバイアスがあることが示されます。
- C.** アルゴリズムが顧客に適していることを確認するために、受け入れテストを実施する必要があります。チームは受け入れ基準を再調整することで、アルゴリズムが検証データセット用に確保された残りの応募者を正確に予測し、バイアスが生じないようにすることができます。
- D.** A/Bテストは、テストデータセットが元のトレーニングデータによってもたらされた可能性のあるバイアスを検出しないことを確認するために使用する必要があります。2つのモデルに大きな差がある場合、元のモデルにバイアスが存在することが示唆されます。

Answer: A (メッセージを残す)

AIシステムにおけるバイアスは、トレーニングデータに固有の偏見が含まれており、モデルが公平な予測を行う際に発生します。経験に基づくテスト、特に探索的データ分析 (EDA) は、トレーニングデータ内のパターン、分布、潜在的な差別要因を分析することで、こうしたバイアスを明らかにするのに役立ちます。

* オプションA：トレーニングデータセットが運用上適切であることを確認するために、経験に基づくテストを実施する必要があります。これには、トレーニングデータセット内のバイアスをチェックするための探索的データ分析 (EDA) の適用が含まれます。」

* 正解です。EDA では、データセットのバイアス、不一致、欠損値を調べ、ML モデルの予測における公平性を確保します。

* オプションB：トレーニングデータセットを使用して作成されたモデルと、テストデータセットを使用して作成された別のモデルを比較するには、バックツーバックテストを使用する必要があります。2つのモデルに大きな差がある場合、元のモデルにバイアスがあることが示されます。」

* バックツーバックテストは回帰テストや AI システムのバージョンの比較に使用されますが、主にバイアスの検出には使用されません。

* オプション C: アルゴリズムが顧客に適しているかどうかを確認するには、受け入れテストを使用する必要があります。

チームは受け入れ基準を再調整して、アルゴリズムが検証データセット用に確保された残りの応募者を正確に予測し、偏りがいないことを確実にするようにすることができます。」

* 受け入れテストは、バイアスを検出して軽減することではなく、事前に定義されたビジネス要件を満たすことに重点を置いています。

* オプションD：A/Bテストは、テストデータセットが元のトレーニングデータによってもたらされた可能性のあるバイアスを検出しないことを確認するために使用する必要があります。2つのモデルに大きな違いがある場合は、元のモデルにバイアスがあることが示されます。」

* A/B テストは、バイアスを明示的に特定するのではなく、モデルのバリエーションを評価するために使用されます。

* バイアステスト方法：AIベースのシステムは、アルゴリズムバイアス、サンプルバイアス、不適切なバイアスについてテストする必要があります。経験に基づくテストとEDAは、バイアスの検出に役立ちます。」

* 探索的データ分析 (EDA) : EDA は、視覚化と統計分析を通じてトレーニング データ内の潜在的なバイアスを明らかにするのに役立ちます」。

回答オプションの分析:ISTQB CT-AI シラバス参照:したがって、オプション A は、ローン申請者モデルのバイアスを検出するのに最適な選択肢です。

最新問題: 45

自律型 AI ベースのシステムが適切に動作していることを確認する際に、次のうちどれを含めることが最も重要ですか？

A. システムがトレーニングデータの正しい分類を自動的に確認することを確認するためのテストケース

B. システムがデータ入力を適切に自動化していることを検出するためのテストケース

C. システムが不必要な人間の介入を促していることを検出するためのテストケース

D. システムが無効な出力データを自動的に抑制することを確認するためのテストケース

Answer: C (メッセージを残す)

自律型AIベースのシステムを検証する際には、適切なレベルの自律性を維持しながら、必要な場合にのみ人間の介入を要求することを保証することが非常に重要です。AIシステムが不必要に人間の入力を求めると、自律性の目的が損なわれ、次のような問題が発生する可能性があります。

* 操作速度を遅くします。

* システムへの信頼を低下させる。

* 意思決定における不適切な信頼閾値を示します。

これは、過度の人間による介入がパフォーマンスの低下につながる自律走行車、AI 駆動型金融取引、ロボットによるプロセス自動化において特に重要です。

* A. システムがトレーニング データの正しい分類を自動的に確認することを確認するためのテストケース# これは、トレーニングの一貫性の検証には関連しますが、自律性の検証には関連しません。

* B. システムがデータ入力を適切に自動化していることを検出するためのテストケース# 関連はありますが、データ自動化は自律性の検証に直接的には対応していません。

* D. システムが無効な出力データを自動的に抑制することを確認するためのテストケース# これは、意思決定の自律性ではなく、出力のフィルタリングに重点を置いています。

なぜ他の選択肢は間違っているのでしょうか?したがって、自律型 AI ベースのシステムを検証するための最も重要なテストケースは、不必要に人間の介入を要求しないことを確認することです。

* セクション 8.2 - 自律 AI ベース システムのテストでは、システムが必要な場合にのみ人間の介入を要求し、自律性を妨げないかどうかをテストすることが重要であると述べています。

ISTQB認定テスターAIテスト学習ガイドからの参考資料:

最新問題: 46

説明した状況に対するテストアプローチとして最適な決定は次のどれですか？

4つの中から1つを選択してください

- A. 特にシステム テストについては、新しいカメラ機能の定期的な回帰テストを手動で実行する予定です。
- B. 統合テスト レベルで古いカメラ モデルのテスト ケースを実行します。動作データ パイプラインのさらなる動的テストは必要ありません。
- C. エンド ユーザーの満足度を確保するために、システム テスト レベルでチーム全体による体験ベースのテストを計画します。
- D. 画像データ セットのレビューと探索的データ分析を実行して、このデータの代表性が欠如するリスクを軽減する予定です。

Answer: C (メッセージを残す)

ISTQB CT-AIシラバスでは、チームの一部にドメイン知識が不足している場合、AIベースのシステムのテストには部門横断的な連携と経験に基づくテストが必要であることが強調されています。このシナリオでは、機械学習の専門家は機械学習とデータセットの準備を理解していますが、カメラシステムの動作、デバイスの運用データパイプライン、エンドユーザーのワークフローに関する知識が不足しています。チームの残りのメンバーはドメインとシステムテストを理解していますが、機械学習については理解していません。セクション4.4 「ヒューマンファクターとAIテスト」およびセクション4.3 「AIコンポーネントのシステムテスト」では、ドメイン理解が不均一な場合、チーム全体（テスター、開発者、ドメイン専門家）による経験に基づくテストが最も効果的なアプローチであると強調されています。これにより、AIの出力が実際のユーザーの期待とシステムの動作と一致することが保証されます。オプションCはまさにこの原則に沿っています。

オプションAは限定的であり、ML統合の検証の必要性に対応していません。オプションBは誤りです。古いテストケースを再利用すると、運用データパイプラインにおけるAI特有のリスクが見落とされてしまうからです。オプションDは有用ですが、データの代表性のみに焦点を当てており、システムレベルのユーザー検証には焦点が当てられていません。したがって、オプションCがシラバスに準拠した最適なテストアプローチです。

有効な **CT-AI** 問題集は GoShiken.com が提供された合格しやすい CT-AI 試験問題集！

GoShiken.com が最新の **CT-AI** 試験問題集を提供しています。GoShiken.com CT-AI 試験問題は最新で、解答が正確でございます。最新の GoShiken.com CT-AI 問題集をゲットする人はこちら: <https://www.goshiken.com/ISTQB/CT-AI-mondaishu.html> (**12230%OFF**問題集溶と正解付きで **30%w** 特別割引コード: **Freepdfdumps**)

最新問題: 47

次のテストのうち、ML モデルのテスト フェーズで実行される可能性が最も低いのはどれですか。1つのオプションを選択

- A. モデルのトレーニング速度をテストします。
- B. モデルによる予測の速度をテストします。
- C. 分類モデルの精度をテストします。

D. ML モデルを活用したサービスの API をテストします。

Answer: A (メッセージを残す)

質問は、MLモデルのテストフェーズで実行される可能性が最も低いテストはどれか、というものです。それぞれの選択肢について考えてみましょう。

* 分類モデルの精度テスト (A): 精度テストは、MLモデルテストフェーズの基本的な部分です。モデルが意図したとおりにデータを正しく分類し、必要なパフォーマンス指標を満たしていることを確認します。

* MLモデルを活用したサービスのAPIテスト B) APIテストは、特にMLモデルがサービスの一部としてデプロイされている場合に重要です。これにより、サービスが他のシステムと適切に統合され、APIが期待どおりに動作することが保証されます。

* モデルの学習速度のテスト (C): これはMLモデルのテストフェーズに含まれる可能性が最も低いです。学習速度は、モデルの最適化とチューニングを行う開発フェーズにおいてより重要になります。テストでは、学習速度よりも、モデルのパフォーマンスと動作に重点が置かれます。

* モデルによる予測速度のテスト (D): 予測速度のテストは、モデルが実稼働環境、特にリアルタイムアプリケーションのパフォーマンス要件を満たしていることを確認するために重要です。

参考文献:

* ISTQB CT-AI シラバスのセクション 3.2 「ML ワークフロー」とセクション 5 「ML 機能パフォーマンス メトリック」では、モデル テスト フェーズでのテストの焦点について説明しています。これには精度と予測速度が含まれますが、トレーニング速度は含まれません。

最新問題: 48

AI ベースのシステムの次の特性のうち、安全性の確保がより困難になるのはどれですか？

A. シンプルさ

B. 持続可能性

C. 非決定性

D. 堅牢性

Answer: C (メッセージを残す)

AIベースのシステムは、しばしば非決定論的な動作を示します。つまり、同じ入力に対して常に同じ出力を生成するとは限りません。システムの動作は新しいデータ、環境要因、またはアップデートに基づいて変化する可能性があるため、安全性の確保はより困難になります。

* 非決定論が安全性に影響を与える理由:

* 従来のソフトウェアでは、同じ入力では常に同じ出力が生成されます。

* AI システムでは、学習したパターンと重みに応じて出力が確率的に変化します。

* この予測不可能性により、特に自動運転車、医療用 AI、産業オートメーションなどの重要な分野では、正確性、信頼性、安全性の検証が難しくなります。

* A (シンプルさ): AI ベースのシステムは通常、単純ではなく複雑であり、安全性の課題につながります。

* B (持続可能性) : 持続可能性AIにとって重要な考慮事項ですが、安全性に直接影響するものではありません。

* D (堅牢性): 堅牢性の欠如により AI システムが安全でなくなる可能性があります、非決定性が安全性の検証を複雑にする主な問題です。

* ISTQB CT-AI シラバス (セクション 2.8: 安全性と AI)

* AI ベースのシステムの安全性を確保することを困難にする特性には、複雑性、非決定性、確率的性質、自己学習、透明性の欠如、解釈可能性と説明可能性、堅牢性の欠如などがあります。」
他の選択肢が間違っている理由: ISTQB 認定テストターの AI テスト学習ガイドからのサポート参考文献: 結論: 非決定性により AI の動作が予測不可能になり、安全性の保証が複雑になるため、正解は C です。

最新問題: 49

BioSearchJ は、X線画像からがんの発生を予測する AI モデルを開発しています。このモデル単体での精度は良好であることが確認されています。しかし、診断ラボで実際に使用してみると、結果の質の低さ、特に実際のがん症例を検出できないという不満がユーザーから寄せられ、モデルの使用が中止されました。

上記のシナリオの原因となったテスト計画の欠陥を見つけるために、テストの専門家が呼び出されました。

次のオプションのうち、テストの専門家によって発見される理由として最も可能性が高いと思われるものはどれですか？

1つのオプションを選択

- A. トレーニング データとテスト データの間に類似性がありません。
- B. 入力データは、テストに使用する前に品質がテストされていません。
- C. 適切な機能パフォーマンス メトリックの選択に重点が置かれていない。
- D. 非機能要件テストに重点が置かれていない。

Answer: A (メッセージを残す)

この質問は、個別の精度は良好であるにもかかわらず、実際のパフォーマンスが低いというシナリオを前提として、テストの専門家によって発見される可能性が最も高い欠陥はどれか、というものです。

* トレーニングデータとテストデータの類似性の欠如 (A): これは機械学習においてよくある問題で、トレーニングデータではモデルのパフォーマンスは良好ですが、トレーニングデータの代表性が欠如しているため、実世界データではパフォーマンスが低下します。これは、新しい未知のデータへの汎化能力の低下につながります。

* 入力データはテストに使用する前に品質テストされていません (B): データの品質は重要ですが、トレーニングデータの代表性と比較すると、このオプションが説明した問題の主な原因となる可能性は低くなります。

* 適切な機能パフォーマンス メトリックの選択に重点が置かれていない (C): 適切なメトリックは重要ですが、説明されている問題はメトリックの選択よりもデータの不一致に関連しているようです。

* 非機能要件テストへの焦点の欠如 (D): 非機能要件は重要ですが、シナリオでは実際のがん症例の検出に関する問題が具体的に言及されており、データの問題が指摘されています。

参考文献:

- * ISTQB CT-AI シラバスのセクション 4.2 「トレーニング、検証、およびテスト データセット」では、モデルが実際のデータに適切に一般化されるようにするために代表的なデータセットを使用することの重要性が強調されています。
- * サンプル試験問題ドキュメント、質問#40では、データの代表性とモデルの一般化に関連する問題を取り上げています。

最新問題: 50

ある野生生物保護団体は、ニューラルネットワークを用いて様々な動物の画像を分類したいと考えています。このアルゴリズムは、ソーシャルメディアプラットフォームで、今月の動物に選ばれた動物の写真を自動的に選び出すために利用される予定です。今月の動物はオオカミです。テストチームは既に、犬とオオカミの特徴が似ていることから、このアルゴリズムが犬の写真をオオカミとして分類できることを確認済みです。このような状況に対応するため、チームはオオカミと犬の画像を追加してモデルをトレーニングし、モデルがオオカミと犬をより正確に区別できるようにする予定です。

追加トレーニング後にモデルが改善されたことを確認するには、どのようなテスト方法を使用する必要がありますか？

- A. この時点ではアプリケーション ドメインが明確に理解されていないため、メタモーフィックテストが行われます。
- B. トレーニングで誤った画像が使用されていないことを確認するための敵対的テスト。
- C. 組み合わせ論を使用して、写真パラメータの長いリストを調べるペアワイズテスト。
- D. トレーニング前のモデルのバージョンと、追加画像でトレーニングした後のモデルの新しいバージョンを使用したバックツーバックテスト。

Answer: D (メッセージを残す)

バックツーバックテストは、2 つの異なるバージョンの ML モデルを比較するために使用されます。これはまさにこのシナリオで必要なことです。

- * モデルは当初、特徴の類似性により犬をオオカミと誤分類しました。
- * テストチームは、犬とオオカミの追加画像を使用してモデルを再トレーニングします。
- * この追加トレーニングによって分類精度が向上したかどうかを確認する最良の方法は、同じテスト データセットを使用して、元のモデルの出力と新しくトレーニングされたモデルの出力を比較することです。
- * A (メタモーフィック テスト): メタモーフィック テストは、既存のテスト ケースに基づいて新しいテスト ケースを生成するのに役立ちますが、異なるモデル バージョンを直接比較するものではありません。
- * B (敵対的テスト): 敵対的テストは、トレーニングの有効性を検証するためではなく、悪意を持って妨害された入力に対してモデルがどの程度堅牢であるかを確認するために使用されます。
- * C (ペアワイズ テスト): ペアワイズ テストは、モデルの改善を検証するのではなく、主要な変数の相互作用に焦点を当ててテスト ケースの数を減らすための組み合わせ手法です。
- * ISTQB CT-AI シラバス セクション 9.3: バックツーバックテスト)

* バックツーバックテストは、更新された ML モデルを以前のバージョンと比較して、パフォーマンスが向上したか、期待どおりであるかを確認する必要がある場合に使用されます。」

* 新しくトレーニングされたモデルの結果は、以前のバージョンの結果と比較され、変更がパフォーマンスに悪影響を与えなかったことが確認されます」。

他の選択肢が誤りである理由 :ISTQB認定テストター向けAIテスト学習ガイドの参考文献：結論：再学習後にモデルのパフォーマンスが向上したことを確認するには、両方のモデルバージョンを比較するバックツーバックテストが最も適切な方法です。したがって、正解はDです。

最新問題: 51

ML を使用する際に AI を実装するのに最も適したハードウェアは次のうちどれですか？

1つのオプションを選択

A. 64 ビット CPU。

B. 高速行列乗算をサポートするハードウェア。

C. 高性能 CPU。

D. 高精度浮動小数点演算をサポートするハードウェア。

Answer: B (メッセージを残す)

A . 64 ビット CPU。

64 ビット CPU は大量のメモリを処理し、複雑な計算を実行するために不可欠ですが、機械学習で一般的に使用される種類の操作に特に最適化されているわけではありません。

B. 高速行列乗算をサポートするハードウェア。

行列乗算は、多くの機械学習アルゴリズム、特にニューラルネットワークやディープラーニングにおける基本的な演算です。GPU (グラフィックス・プロセッシング・ユニット)などの高速行列乗算に最適化されたハードウェアは、これらの演算に必要な並列処理を効率的に処理できるため、AI やMLの実装に最適です。

C . 高性能 CPU。

高性能 CPU は、汎用コンピューティング タスクや ML の一部の側面には役立ちますが、行列乗算やその他の ML 固有のタスクには、GPU などの専用ハードウェアほど効率的ではありません。

D . 高精度浮動小数点演算をサポートするハードウェア。

高精度の浮動小数点演算は科学計算や一部の特定の AI タスクにとって重要ですが、多くの ML アプリケーションでは、高精度だけよりも高速な行列乗算の方が重要です。

したがって、GPU などの高速行列乗算をサポートするハードウェアは、機械学習の並列処理要件に最も適しているため、正解は B です。

最新問題: 52

AIを用いて適切な運転行動と反応を決定する自動運転車をテストしています。テスト対象のパラメータと組み合わせを評価した結果、制限時間内にテストするには数が多すぎると判断しました。パラメータを制限するためにペアワイズテストを使用することを提案されました。テスト対象ソフトウェアの複雑さを考慮すると、ペアワイズテストを使用することでどのような結果が得られる可能性がありますか？

- A. テストするパラメータの数は12個未満に減らすことができます
- B. 優先度の高い欠陥はすべてこの方法で特定されます
- C. 必要なテストの数は減らすことができますが、それでもテストセットが十分に大きいため、すべてを実行するには自動化が必要になる場合があります。
- D. この問題には AI が関与しており、進化する値によって検証できない予期しない結果が生じる可能性があるため、ペアワイズ法は適用できません。

Answer: C ([メッセージを残す](#))

シラバスには、ペアワイズ テストは必要なテスト ケースの数を減らすことで欠陥を見つけるのに効果的である一方、結果として得られるテスト スイートは依然として広範囲にわたる可能性があります、自動化が必要になると記載されています。

ペアワイズテストを使用した場合でも、テストスイートが大規模になる可能性があります。必要なテストを実行するには、自動化と仮想テスト環境が必要になることがよくあります。」(参照: ISTQB CT-AIシラバスv1.0、セクション9.2、99ページ中67ページ)

最新問題: 53

確率のおよび非決定論的な AI ベースのシステムに関連するテストの課題を克服するのに役立つアプローチは次のどれですか？

- A. AIが常に同じ正しいテスト結果を返すことを確認するために、テストを複数回実行します。
- B. システムテストを複数のデータ取り込みテストに分解して、AIシステムが十分な量の入力データを取得しているかどうかを判断します。
- C. システムテストを複数のデータ取り込みテストに分解して、AIシステムが正確で正確な入力データを取得しているかどうかを判断します。
- D. 適切な数の回答が正確であることを確認するために、統計的に有効なテスト結果を生成するためにテストを複数回実行します。

Answer: ([解答を表示する](#)**)**

シラバスには次のように記載されています。

確率的システムと非決定的システムをテストする場合、同じ入力で異なる出力が生成されることがあります。

統計的に有効なテスト結果を得るには、テストを複数回実行し、適切な数の回答が正確であることを確認する必要があります。(参照ISTQB CT-AIシラバスv1.0、セクション8.4、99ページ中58ページ)

最新問題: 54

回帰テストの選択を最適化し、回帰スイートが大きくなるのを防ぐための最適なオプションは次のうちどれですか？

1つのオプションを選択

- A. テストケースの複雑さを考慮して適切なテストを特定します。
- B. テストのランダムなサブセットを使用します。
- C. AI ベースのテスト自動化ツールを使用してテスト スクリプトを自動化します。

D. AIベースのツールを使用して過去のテスト結果を分析することで回帰テストスイートを最適化する

Answer: D ([メッセージを残す](#))

A. テストケースの複雑さを考慮して適切なテストを特定します。

複雑性分析は重要なテストケースの選択に役立ちますが、回帰スイート全体を効果的に最適化するという問題に直接対処するものではありません。

B. テストのランダムなサブセットを使用する。

テストケースをランダムに選択すると、重要なテストを見逃してしまう可能性があり、回帰テストスイートの最適化も保証されません。このアプローチには、包括的なカバレッジを確保するための体系的な方法が欠けています。

C. AIベースのテスト自動化ツールを使用してテストスクリプトを自動化します。

自動化はテストを効率的に実行するのに役立ちますが、テストスイートが大きくなりすぎないようにテストの選択を本質的に最適化するものではありません。

D. AIベースのツールを使用して過去のテスト結果を分析することで回帰テストスイートを最適化します。

これは最も効果的なアプローチです。AIベースのツールは過去のテストデータを分析し、パターンを特定し、過去の結果に基づいて欠陥を検出する可能性の高いテストを優先順位付けできるためです。この手法により、最も影響の大きいテストケースに焦点を当てることで、最適化され管理しやすい回帰テストスイートが実現します。

したがって、AIベースのツールを使用して過去のテスト結果を分析することが、回帰テストの選択を最適化し、回帰スイートのサイズを効果的に管理するための最善のオプションであるため、正解はDです。

最新問題: 55

地元企業では、オフィスに郵便物の集配ロボットを導入しています。現在、ロボットは集配場所間を移動する際にトラックを使用しています。目的地に到着すると、ロボットは停止し、人間が郵便物を取り出したり、投函したりできます。そこで、このロボットにAI機能を搭載し、トラックを使わず、障害物にぶつかることなく、人間の介入なしに業務を遂行できるようにアップグレードすることを決定しました。

テストチームは、ロボットのアップグレードテストで使用する新規および既存のテスト目標と受け入れ基準のリストを作成しています。以下のテスト目標のうち、このシステムのAI品質特性をテストするのはどれですか？

A. ロボットは経路を最適化するために進化する必要がある

B. ロボットは1日6時間以内に充電する必要があります

C. ロボットは各配達の日時を記録し、それをレポートにまとめる必要がある。

D. ロボットは毎日99.99%の配達を完了する必要がある

Answer: ([解答を表示する](#)**)**

シラバスでは、AIベースのシステムの進化特性とは、環境の変化やシステム自体のパフォーマンスの変化に応じてシステムが進化し、その動作に適応する能力を意味します。

進化とは、システムが新たな状況、異なるハードウェア、あるいは変化する運用環境に適応するために自らを変化させる能力である。」（参考ISTQB CT-AIシラバスv1.0、セクション2.3）

最新問題: 56

次のテストのうち、ML パイプラインでさまざまな種類のバイアスを検出するのに役立つテストを最もよく表しているのはどれですか。

1つのオプションを選択

- A. トレーニング データ内の分布シフトに不適切なバイアスがないかテストします。
- B. モデル評価中にデータのバイアスについてモデルをテストします。
- C. アルゴリズムの偏りのソースについてデータ パイプラインをテストします。
- D. 入力テスト データに潜在的なサンプル バイアスがないか確認します。

Answer: B ([メッセージを残す](#))

ML パイプラインのバイアス検出には、ML プロセス全体の公平性と正確性を確保するためのさまざまなテストが含まれます。

* トレーニングデータにおける分布のシフトをテストし、不適切なバイアスを検出する (A): これは、モデルのバイアスにつながる可能性のあるデータ分布のシフトの有無を確認することを意味します。これは重要なテストですが、バイアスを検出するための最も直接的な方法ではありません。

* モデル評価中にデータバイアスをテストする (B) これは、モデルを評価し、トレーニングに使用したデータにバイアスがないか検出する重要な段階です。これにより、モデルに潜在するデータバイアスに直接対処します。

* データパイプラインにおけるアルゴリズムバイアスの発生源のテスト (C): このテストは、パイプライン内のデータ処理および変換段階から発生する可能性のあるバイアスを特定するのに役立ったため、非常に重要です。アルゴリズムバイアスの発生源を検出することで、モデルがこれらのプロセスからバイアスを継承しないようにすることができます。

* 入力テスト データに潜在的なサンプル バイアスがないか確認します (D): これは重要なステップですが、全体的なデータ パイプラインよりも入力データに重点が置かれます。

したがって、MLパイプラインにおけるさまざまな種類のバイアスを検出するのに最も役立つテストは、B. モデル評価中にデータバイアスについてモデルをテストすることです。

:

ISTQB CT-AI シラバスのセクション 8.3 「アルゴリズム、サンプル、不適切なバイアスのテスト」では、ML パイプラインのさまざまな段階でバイアスを検出するために実行できるさまざまなテストについて説明します。

サンプル試験問題ドキュメントの質問 #32 では、モデルのバイアス評価の重要性が強調されています。

最新問題: 57

ある航空会社は、将来のフライトの燃料需要を予測するための機械学習モデルを作成しました。このモデルは、風速や気温などの気象データをインポートし、航空管制局から取得した過去の飛

行経路に基づいて飛行経路を計算し、乗客と手荷物の平均重量から積載量を推定します。このモデルは夏の間、航空会社にとって許容範囲内の性能を示しましたが、冬が近づくにつれて積載重量の精度が低下しました。探索的なデータ分析を行った結果、手荷物の重量は夏よりも冬の方が高いことが明らかになりました。

次の記述のうち、問題を最もよく表しているもの、およびそれをどのように防ぐことができたかを示すものはどれですか。

- A. モデルはドリフトの影響を受けるため、ドリフトの発生が問題を軽減できるほど早く検出されるように定期的にテストする必要があります。
- B. このモデルはドリフトの影響を受けているため、より透明性のある新しいモデルが開発されるまで、パフォーマンス基準を緩和する必要があります。
- C. モデルは破損しているため、使用中のコンピュータシステムに再ロードする必要があります。できれば、さらなる変更を防ぐためにバージョン管理の方法を使用してください。
- D. このモデルは透明性が欠如しているため、定期的にテストして、進行性のエラーが早期に検出され、問題が軽減されるようにする必要があります。

Answer: A ([メッセージを残す](#))

シラバスには次のように記載されています。

運用環境が変化しても、学習済みモデルがそれに応じて変化しない場合、コンセプトドリフトが発生します。モデルの出力は精度が低下し、有用性も低下します。したがって、運用モデルは受け入れ基準に照らして定期的に評価する必要があります。(参照ISTQB CT-AIシラバスv1.0、セクション7.6、99ページ中54ページ)

最新問題: 58

AI ベースのシステムのテスト データを処理する際に課題となるのは次のうちどれですか。

- A. 個人データまたは機密データ
- B. 出力データまたは中間データ
- C. ビデオのフレーム速度またはアスペクト比
- D. データフレームワークまたは機械学習フレームワーク

Answer: A ([メッセージを残す](#))

AIベースのシステムにおけるテストデータの取り扱いには、特にデータのプライバシーと機密性に関して多くの課題が伴います。AIモデルは多くの場合、膨大な量のトレーニングデータを必要とし、その中には個人情報、機密情報、あるいは機密情報が含まれている可能性があります。データ保護法 (GDPR、CCPAなど) への準拠を確保し、安全なデータ取り扱い方法を実施することは、AIテストにおける大きな課題です。

* データプライバシー規制

* AI ベースのシステムは、画像、名前、取引の詳細などの個人データを頻繁に処理するため、プライバシーに関する懸念が生じます。

* GDPR (一般データ保護規則) や CCPA (カリフォルニア州消費者プライバシー法) などの規制に準拠するには、機密データをテストに使用する前に、適切に匿名化、暗号化、または編集する必要があります。

* データセキュリティの課題

* 適切なセキュリティ対策が実施されていない場合、AI モデルによって機密情報が漏洩する可能性があります。

* トレーニングおよびテスト データを不正アクセスから保護することは、信頼とコンプライアンスを維持するために重要です。

* 法的および倫理的考慮事項

* 組織は、特定のデータセット、特に健康記録、財務データ、または個人を特定できる情報 (PII) を含むデータセットを使用する前に、法的承認を取得する必要があります。

* テスト担当者は、露出リスクを最小限に抑えるために合成データまたはデータ マスキング技術を採用する必要がある場合があります。

* (B) 出力データまたは中間データ#

* 出力データの分析は重要ですが、個人情報や機密性の高いテストデータの処理に比べると、それほど大きな課題にはなりません。

* (C) ビデオのフレーム速度またはアスペクト比#

* これらは AI モデルの処理における技術的な課題ですが、データのプライバシーや倫理的な考慮事項には該当しません。

* (D) データフレームワークまたは機械学習フレームワーク#

* 適切な ML フレームワーク (TensorFlow、PyTorch など) を選択することは重要ですが、テストデータの処理に関連する大きな課題ではありません。

* 個人情報や機密データの取り扱いは、AI テストにおける重要な課題です。個人情報やその他の機密データには、サニタイズ、暗号化、編集のための特別な技術が必要になる場合があります。また、使用にあたっては法的な承認が必要になる場合もあります。」オプション A が正しいのはなぜですか?他のオプションが間違っているのはなぜですか?ISTQB 認定テスターによる AI テスト学習ガイドからの参照したがって、AI ベースのシステムのテストデータを扱う際には、データのプライバシーと機密性が大きな課題となるため、オプション A が正解です。

最新問題: 59

要件から生成される AI 生成テスト ケースに関する問題は次のうちどれですか。

A. 速度が遅く、通常は許可された時間内に実行できません。

B. 要件の微妙な違いを検出できないため、欠陥が発生しやすくなります。

C. ターゲットの障害を誘発するためのステップ数が多くなるため、デバッグが複雑になります。

D. 通常、期待される結果が得られないため、検証が困難になるか、重大な障害の検出のみに頼らざるを得なくなります。

Answer: (解答を表示する)

AI生成のテストケースは、多くの場合、機械学習 (ML) モデルやヒューリスティックアルゴリズムを用いて作成されます。これらの方法は、大量のテストケースを迅速に生成するのに効果的ですが、「テストオラクル問題」に悩まされることがよくあります。

- * テストオラクル問題: テストオラクルは、テストケースの期待される出力を決定するために使用されるメカニズムです。AIベースのツールは、正しい出力が何であるかを本質的に理解していないため、AIによって生成されたテストケースは期待される結果が得られないことがよくあります。
- * 検証の難しさ: 期待される結果が得られないと、テストケースの検証は困難になります。テストターは、従来の合否判定ではなく、ヒューリスティック、異常検出、あるいは重大な障害に頼らざるを得なくなります。
- * A (実行時間の遅さ): AI生成テストは通常、自動化され、効率性を重視して設計されています。本質的に遅いわけではなく、手動で記述したテストよりも高速に実行される場合が多いです。
- * B (ニュアンスの問題により欠陥が発生しやすい): AI生成テストは要件の複雑さに苦勞する可能性があります、ニュアンスを検出できないために失敗するのではなく、主に期待される結果が得られません。
- * C (ステップ数が多いためデバッグが複雑): AI生成テストでは、障害の再現に必要なステップ数を制限することで、デバッグの複雑さを軽減しました。
- * ISTQB CT-AI シラバス (セクション 11.3: テストケース生成における AI の使用)
- * AIによって生成されたテストケースでは、期待される結果が得られないことが多く、テストオラクルなしでは正確性を検証することが困難です。」
- * 検証では、事前に定義された期待される結果よりも、重大な障害を検出することに依存することがよくあります。」

他の選択肢が誤りである理由: ISTQB認定テストター向けAIテスト学習ガイドの参考資料: 結論AI生成のテストケースは期待通りの結果にならないことが多いため、検証が困難になり、テストターは正確な合否判定ではなく、重大な失敗に焦点を当てる必要があります。したがって、正解はDです。

最新問題: 60

プロジェクトでは未解決の不具合のバックログがどんどん増えています。開発者は、どの開発者がどの種類のソフトウェアを担当し、どのようなスピードで問題解決を行っているかを学習した機械学習モデルを作成しています。このモデルをどのように活用すれば、バックログを削減し、より効率的な不具合解決を実現できるでしょうか？

- A. 修正にかかる予想時間、修正の速度、回帰の可能性に基づいて、欠陥を自動的に優先順位付けするために使用します。
- B. 問題を解決するために最適な開発者に不具合を割り当て、開発者間で不具合の割り当ての負荷を分散するために使用します。
- C. これを使用して、各欠陥の根本原因を特定し、最も一般的な根本原因を除去するために実装できるプロセス改善計画を策定します。
- D. これを使用してコードをレビューし、より多くの欠陥が発生する可能性のある場所を特定し、その領域を対象にテストを実施します。

Answer: B ([メッセージを残す](#))

AIとMLモデルは、欠陥解決プロセスの最適化において重要な役割を果たすことができます。ISTQB認定テストターAIテスト (CT-AI) シラバスによると、MLモデルは欠陥レポートの分析、重

大な欠陥の優先順位付け、過去の欠陥解決パターンに基づく開発者への欠陥の割り当てに使用できます。

欠陥管理における主な AI アプリケーションは次のとおりです。

- * 欠陥の分類 - NLP 技術は欠陥レポートを分析し、重大度や影響などのメタデータに基づいて欠陥を分類できます。

- * 欠陥の優先順位付け - 過去の欠陥に基づいてトレーニングされた ML モデルは、どの問題が障害を引き起こす可能性が高いかを予測できるため、チームは最も重要な問題を優先できます。

- * 欠陥の割り当て - AI ベースのモデルは、特定の欠陥に最適な開発者を提案し、過去のパフォーマンスと専門性に基づいて解決プロセスを最適化します。

与えられた回答の選択肢から:

- * オプション A (自動優先順位付け) は便利ですが、開発者の専門知識とワークロードのバランスを考慮してバックログを直接効率的に削減するわけではありません。

- * オプション C (プロセス改善のための根本原因分析) は長期的な戦略ですが、バックログの削減には直接対応しません。

- * オプション D (テストに重点を置いた欠陥予測) は、問題を事前に特定するのに役立ちますが、既存のバックログは解決しません。

したがって、オプション B は、履歴データに基づいて最も適切な開発者に欠陥を割り当てる AI の機能と一致し、効率的な欠陥解決とバックログの削減を保証するため、最適な選択肢となります。

認定テスター AI テスト学習ガイド 参考文献:

- * ISTQB CT-AI シラバス v1.0、セクション 11.2 (報告された欠陥の分析に AI を使用する)

- * ISTQB CT-AI シラバス v1.0、セクション 11.5 (欠陥予測のための AI の使用)。

最新問題: 61

データ準備のためのデータ取得アクティビティにおける 3 つのアクティビティは次のどれですか。

A. クリーニング、変換、拡張

B. 特徴選択、特徴成長、特徴拡張

C. 識別、収集、ラベル付け

D. 構築、承認、展開

Answer: (解答を表示する)

ISTQB 認定テスター AI テスト (CT-AI) のシラバスによると、機械学習 (ML) ワークフローのデータ準備における重要なステップであるデータ取得は、次の 3 つの主要なアクティビティで構成されます。

- * 識別 : このステップでは、トレーニングと予測に必要なデータの種類を決定します。例えば、自動運転車のアプリケーションでは、レーダー、ビデオ、レーザー画像、LiDAR (光検出と測距) データなどのデータタイプが必要なソースとして識別される場合があります。

- * 収集 : 必要なデータの種類を特定した後、データ収集元と適切な収集方法を決定します。例えば、国際通貨基金 (IMF) から金融データを収集し、AI ベースのシステムに統合することが挙げられます。

* ラベリング：収集されたデータに注釈またはタグを付け、教師あり学習モデルにとって意味のあるものにするプロセスです。ラベリングは、機械学習アルゴリズムがカテゴリを区別し、正確な予測を行うために不可欠なアクティビティです。

これらのアクティビティにより、データが機械学習モデルのトレーニングとテストに適していることが保証され、データ準備の基盤が形成されます。

有効な **CT-AI** 問題集は GoShiken.com が提供された合格しやすい CT-AI 試験問題集！

GoShiken.com が最新の **CT-AI** 試験問題集を提供しています。GoShiken.com CT-AI 試験問題は最新で、解答が正確でございます。最新の GoShiken.com CT-AI 問題集をゲットする人はこちら：<https://www.goshiken.com/ISTQB/CT-AI-mondaishu.html> (**12230%OFF**問題集溶と正解付きで **30%w**特別割引コード: **Freepdfdumps**)

最新問題: 62

次のどれが過剰適合の例ですか？

- A. モデルは、新しいタイプのデータに対応するために一般化することができません。
- B. モデルはデータに対して単純すぎます。
- C. モデルに入力と出力間の関係がありません。
- D. モデルはノイズまたは外れ値であると判断されたデータを破棄します。

Answer: A (メッセージを残す)

過学習は、機械学習 (ML) モデルがトレーニングデータに特化しすぎたパターンを学習し、新しい未知のデータに対する一般化が欠如してしまう場合に発生します。これは、モデルがトレーニングデータでは非常に優れたパフォーマンスを示す一方で、検証データやテストデータでは、根本的なパターンを学習するのではなく、ノイズや些細な詳細を記憶しているためにパフォーマンスが低下することを意味します。

* オプション A: 「モデルは、新しいタイプのデータに対応するために一般化することができません。」

* これは過学習の正しい定義です。モデルがトレーニングデータを超えて一般化できない場合、新しい入力に苦労し、結果として過学習が発生します。

* オプション B: 「モデルはデータに対して単純すぎる。」

* これは過剰適合ではなく、不足適合を表します。不足適合は、モデルが単純すぎてデータの根本的なパターンを捉えられない場合に発生します。

* オプション C: 「モデルには入力と出力の関係がありません。」

* これは、モデルがデータ内の重要な関係性を捉えられない、アンダーフィッティングとも一致します。

* オプション D: 「モデルはノイズまたは外れ値とみなしたデータを破棄します。」

* 一部の ML モデルでは外れ値を無視する場合がありますが、モデルが学習プロセスでノイズや外れ値を破棄せずに含めた場合に、実際に過剰適合が発生します。

- * オーバーフィッティングの定義：「オーバーフィッティングは、モデルがデータポイントのセットに近すぎて適切に一般化できない場合に発生します。トレーニングデータではうまく機能しますが、新しいデータではうまく機能しません。」
- * オーバーフィッティングのテスト：「トレーニングデータセットとは完全に独立したデータセットでモデルをテストすることで、オーバーフィッティングを検出できる場合があります」回答オプションの分析:ISTQB CT-AIシラバス参考文献:

最新問題: 63

モバイルアプリのスタートアップ企業が、eコマース顧客向けにAIベースのチャットアシスタントを実装しています。テスト計画の過程で、チームは仕様が不十分であることに気づきました。このシステムをテストするにはどのテスト手法を使用する必要がありますか？

- A. 探索的テスト
- B. 静的解析
- C. 同値分割
- D. 状態遷移テスト

Answer: (解答を表示する)

シラバスでは、仕様が不十分であったりテスト オラクルの問題がある場合に探索的テストが特に有効であると説明されています。

探索的テストは、AIベースのシステムによくあるように、仕様が不十分であったり、テストオラクルに問題がある場合などに特に有効です。」（参考ISTQB CT-AIシラバスv1.0、セクション 9.6、99ページ中70ページ）

最新問題: 64

CleverPropose システムのテストに最適な 2 つのテスト手順はどれですか？
2つのオプションを選択してください（5つのうち2つ）

- A. 連続テスト
- B. 敵対的テスト
- C. メタモルフィックテスト
- D. 探索的データ分析
- E. ペアワイズテスト

Answer: A,C (メッセージを残す)

ISTQB CT-AIシラバスでは、オラクル問題が存在する場合、または限定的な回帰テストが利用可能な場合、AIベースの意思決定支援システムは、バックツーバックテストとメタモルフィックテストから大きなメリットを得られると説明されています。このシナリオでは、CleverProposeが古いアドバイザーシステムを置き換えます。バックツーバックテスト（オプションA）は、既存の従来型システムの出力を参照として使用できるため、新しいAIシステムとの比較が可能になるため、理想的です。これはまさに、AIが従来の決定論的システムを置き換える際にシラバスで推奨されている方法です。

セクション4.6 「メタモーフィック関係」で述べられているように、メタモーフィックテスト オプションC)も適切です。限定的な回帰テストと複雑な意思決定ロジックを用いることで、テスターは「顧客の収入が増加しても、リスク評価は悪化しない」といったメタモーフィック関係を定義できます。これらの関係により、正確な期待出力が得られない場合でも検証が可能になります。探索的データ分析 オプションD)はシステムテスト手法ではありません。ペアワイズテスト オプションE)は、複雑なAIベースの金融アドバイスシステムには適していません。敵対的テスト オプションB)は、セキュリティが重要な評価や堅牢性の評価に適しており、アドバイザリツールの主要なシステムテストには適していません。

したがって、A と Care は正しい選択肢であり、シラバスに準拠しています。

最新問題: 65

エンジン製造工場では、機械学習を用いて不良ボルトを検出したいと考えています。モデルにバイアスが生じる原因となるのは次のうちどれでしょうか？

- A. 特定の障害状態を意図的に除外してトレーニングデータを選択する
- B. 既知のすべての障害状態を意図的に含めてトレーニングデータを選択する
- C. トレーニングデータセットとは異なるデータセットからテストデータを選択する
- D. ボートメーカーのボルト寿命データからテストデータを選択する

Answer: ([解答を表示する](#))

AIモデルのバイアスは、多くの場合、不完全または代表性に欠けるトレーニングデータに起因します。この場合、トレーニングデータセットが特定の障害状態を意図的に除外していると、機械学習モデルは現実世界のシナリオにおいてこれらの状態を学習 検出できなくなります。

結果は次のようになります:

- * サンプルバイアス。トレーニング データは、起こりうるすべての障害状態を完全には代表していません。
- * アルゴリズムのバイアス。モデルが特定の欠陥タイプを優先し、他の欠陥タイプを無視します。
- * B. 既知のすべての障害状態を意図的に含めてトレーニング データを選択する# これにより、モデルの一般化が向上し、バイアスを軽減できます。
- * C. トレーニング データセットとは異なるデータセットからテスト データを選択する# これはモデルの一般化を評価するための良い方法ですが、本質的にバイアスを導入することはありません。
- * D. ボート製造業者のボルト寿命データからテストデータを選択する# 無関係なデータを使用するとモデルの精度が低下する可能性があります、誤ったデータセット内の体系的なパターンが不公平な意思決定につながる限り、直接バイアスが導入されることはありません。
- * セクション 8.3 - アルゴリズム、サンプル、および不適切なバイアスのテストでは、トレーニングデータセットが予想されるデータ空間を完全に代表していない場合、サンプル バイアスが発生し、偏った予測につながる可能性がありますと述べています。

他の選択肢が間違っているのはなぜでしょうか?ISTQB認定テスターAIテスト学習ガイドからの参照:

最新問題: 66

あるスタートアップ企業が、モバイルデバイス向け銀行アプリケーションに新しい顔認識システムを実装しました。このアプリケーションは、デバイス上で実行時に学習し、ユーザーにアクセスを許可するかどうかを判断するように設計されています。また、インターネット経由でアプリケーション開発者にフィードバックを送信します。アプリケーションの導入により、モバイルデバイスが頻繁に再起動されるようになりました。

失敗の原因として最も可能性が高いのは次のどれですか？

- A. フィードバックには物理的な接続が必要であり、インターネット経由で送信することはできません。
- B. モバイル オペレーティング システムは機械学習アルゴリズムを処理できません。
- C. アプリケーションのサイズが携帯電話のストレージ容量を大量に消費しています。
- D. トレーニング、処理、および診断の生成は、モバイル デバイスのハードウェアでは処理できないほど計算負荷が大きすぎます。

Answer: D (メッセージを残す)

\

顔認識アプリケーションには、次のような複雑な計算タスクが伴います。

- * 特徴抽出 - 顔の独特な特徴を識別します。
 - * モデルのトレーニングと更新 - ユーザーデータの継続的な学習と適応。
 - * 画像処理 - ささまざまな照明と角度でのリアルタイム画像認識を処理します。
- このシナリオでは、モバイル デバイスが継続的に再起動しており、過剰な処理要求によってリソースが過負荷になっていることが示唆されます。
- * モバイル デバイスの計算能力には限界があります。
 - * サーバーとは異なり、モバイル デバイスにはディープラーニング モデルに必要な強力な GPU/TPU がありません。
 - * デバイス上での学習は計算コストがかかります。
 - * モデルはリアルタイム学習を実行している可能性があり、CPU と RAM に過度の負荷をかける可能性があります。
- ※フィードバックを連続送信すると過熱の原因となります。
- * システムが複数のプロセス (トレーニング、推論、ネットワーク通信) を実行している場合、システム リソースが過負荷になり、クラッシュが発生する可能性があります。
 - * (A) フィードバックには物理的な接続が必要であり、インターネット経由では送信できません。 #(誤り)
- ※クラウドベースのAIサービスでは、インターネット経由でのフィードバック送信が一般的です。これが問題の原因ではありません。
- * (B) モバイルオペレーティングシステムは機械学習アルゴリズムを処理できません。 #(誤り)
 - * 多くのモバイルアプリケーションはMLモデルを効率的に使用しています。ここで問題となるのは、OSのMLアルゴリズム実行能力ではなく、計算負荷の高さです。
 - * (C) アプリケーションのサイズが携帯電話のストレージ容量を大量に消費しています。 #(誤り)

- * ストレージの問題は通常、デバイスの再起動ではなく、インストールの失敗や遅延を引き起こします。ここでの問題は、ストレージスペースではなく、処理の過負荷です。
- * AI ベースのアプリケーションには、かなりの計算能力が必要です。AI ベースのアプリケーションの計算能力は、リソースが限られたデバイスに展開する場合に課題となる可能性があります。」
- * エッジデバイスは、複雑な ML ワークロードの処理に苦勞する可能性があります。モバイルデバイスやエッジデバイスはクラウド環境に比べて処理能力が限られているため、AI モデルをデプロイするには最適化が必要です。」オプション D が正しい理由は何ですか?他のオプションが間違っている理由は何ですか?ISTQB 認定テストターの AI テスト学習ガイドからの参照したがって、顔認識システムの計算要求はモバイルハードウェアが処理するには高すぎるため、継続的な再起動が発生するため、オプション D が正解です。

最新問題: 67

観光客が航空会社に電話してチケットを予約すると、音声を認識し、チケット購入に関連する要求を理解し、適切な旅行オプションを提供できる自動システムに接続されます。

観光客が目的地の天候予想や、労働市場の逼迫による運航への影響について質問すると、自動システムからの返答は「質問の意味がわかりません」のみ。このAIシステムは、どのような分類になるべきでしょうか?

- A. 汎用AI
- B. ナローAI
- C. スーパーAI
- D. 従来 of AI

Answer: B (メッセージを残す)

限定的AI (弱いAIとも呼ばれる)は、一般的な知能や意識を持たずに特定のタスクを実行するように設計されています。質問のAIシステムは、音声を認識し、予約関連の特定のリクエストに回答することはできますが、無関係なトピック (天気や労働市場など)について質問されると回答できません。

* オプションA : 汎用AI」

* 誤り。汎用AI (AGI)とは、人間が実行できるあらゆる知的タスクを実行できるAIシステムを指します。ここで説明するシステムは特定のタスクに特化しており、汎用的な知能を備えているわけではありません。

* オプションB : 狭義のAI」

* 正解です。AIシステムは事前定義されたドメイン (チケット予約)に限定されており、無関係な質問を処理できません。これは、特定のタスクには優れているものの、より広範な認知能力を欠く、特化型AIの特徴です。

* オプションC : スーパーAI」

* 誤り。スーパー AI は人間の知能を超え、高度な推論能力と創造性を発揮します。シナリオ内の AI はこのレベルには程遠いです。

* オプションD : 従来 of AI」

* 誤り。従来型AIは、ルールベースのシステムを含む可能性のある、より広義の用語です。ここで説明するシステムは機械学習と自然言語処理に依存しており、より狭義のAIに近いと言えます。

* 狭義 AI の定義: 狭義 AI とは、汎用的な知能を持たずに、単一のタスクまたは限られた一連のタスクを実行するように設計された AI システムを指します」。

* 汎用 AI と限定的 AI: 汎用 AI は依然として研究分野ですが、現在の AI アプリケーションのほとんどは限定的 AI のカテゴリに分類されます」。

回答オプションの分析:ISTQB CT-AI シラバス参照:したがって、オプション B は AI ベースのチケット予約システムの正しい分類です。

最新問題: 68

テキストメッセージに次に入力する単語を予測する自然言語処理 (NLP) アルゴリズムを考えてみましょう。このアルゴリズムには、ユーザーの入力パターンに基づいた予測精度を向上させるアップデートが作成されました。以前のアルゴリズムの精度はユーザーによって評価されました。その後、新しいアップデートがリリースされた後、ユーザーはアップデートされたアルゴリズムを評価しました。統計的検定を用いて、2つのバージョンのアルゴリズムを比較し、アップデートを継続すべきかどうかを判断しました。

これはどのようなタイプのテストの例ですか？

A. メタモルフィックテスト

B. A/Bテスト

C. 探索的テスト

D. ペアワイズテスト

Answer: (解答を表示する)

A/Bテストは、システムの2つの異なるバージョンを比較し、どちらのパフォーマンスが優れているかを判断する統計的テスト手法です。このシナリオでは、古いNLPアルゴリズムの精度を評価し、アップデート後に新しいアルゴリズムもユーザーによる評価を受けました。2つのバージョンを比較するための統計的テストは、A/Bテストの基本的なアプローチです。

A/B テストは次のような場合によく使用されます。

* ユーザー エクスペリエンス テスト (例: Web サイトの異なるバージョンの比較)。

* ML モデルの評価 (例: 2 つの AI ベースの分類器の比較)。

* パフォーマンス評価 (例: 新しい推奨アルゴリズムがより効果的かどうかを判断する)。

このアプローチにより、データに基づいた意思決定が可能になり、システムへの変更が有意義な改善につながる事が保証されます。

* セクション 9.4 - A/B テストでは、A/B テストは AI ベースのシステムの更新を比較し、新しいバージョンが優れているかどうかを判断するために使用されると述べています。

ISTQB認定テスターAIテスト学習ガイドからの参考資料:

最新問題: 69

ニューラル ネットワーク内のニューロンの活性化値出力は、ニューロンに計算を適用することによって得られます。

活性化値の計算に使用される入力を最もよく表すオプションは次のどれですか？

1つのオプションを選択

- A. ニューロン レベルでの個々のバイアス、前の層のニューロンの活性化値、およびニューロン間の接続に割り当てられた重み。
- B. 前の層のニューロンの活性化値と、ニューロン間の接続に割り当てられた重み。
- C. ニューロン レベルでの個々のバイアスと、ニューロン間の接続に割り当てられた重み。
- D. ニューロン レベルでの個々のバイアスと、前の層のニューロンの活性化値。

Answer: A (メッセージを残す)

ニューラルネットワークでは、ニューロンの活性化値は、前の層からの入力、接続の重み、そしてニューロンレベルのバイアスの組み合わせによって決定されます。詳細な内訳は以下のとおりです。

アクティベーション値の入力:

前の層のニューロンの活性化値: これらは、現在のニューロンへの入力として機能する、前の層のニューロンからの出力です。

接続に割り当てられた重み: ニューロン間の各接続には重みが関連付けられており、入力信号の強度と方向を決定します。

ニューロン レベルでの個別のバイアス: 各ニューロンには入力合計を調整するバイアス値があり、活性化関数をシフトできます。

計算:

活性化値は、前の層からの重み付けされた入力を合計し、バイアスを追加することによって計算されます。

式: $z = \sum(w_i a_i) + b_z = \sum(w_i a_i) + b$ 、ここで、 w_i は重み、 a_i は前のレイヤーからのアクティベーション値、 b はバイアスです。

次に、この合計に活性化関数 (シグモイド、ReLU など) を適用して、最終的な活性化値を取得します。

オプションAが正しい理由:

オプション A は、活性化値の計算に関係するすべてのコンポーネント (個々のバイアス、前の層の活性化値、および接続の重み) を正しく識別します。

他の選択肢を排除する:

B. 前の層のニューロンの活性化値と、ニューロン間の接続に割り当てられた重み: このオプションでは、非常に重要なバイアスが考慮されません。

C. ニューロンレベルでの個々のバイアスと、ニューロン間の接続に割り当てられた重み: このオプションでは、前のレイヤーからの活性化値が失われます。

D. ニューロンレベルでの個々のバイアスと、前の層のニューロンの活性化値: このオプションでは、重要な重みが失われます。

参照:

ISTQB CT-AI シラバスのセクション 6.1 「ニューラル ネットワーク」では、ニューラル ネットワーク内のニューロンのコンポーネントと機能について説明します。

「ニューラル ネットワークの活性化関数」(ISTQB CT-AI シラバス、セクション 6.1.1)。

最新問題: 70

AI システムが適応できると予想される入力変更の例は次のどれですか。

- A. 猫を認識するように訓練されており、犬の画像が与えられている
- B. 特定の解像度で人間の顔を認識するように訓練されており、より高い解像度で撮影された人間の顔画像が与えられる。
- C. 数学モデルを分析するように訓練されており、分類するための風景写真のセットが与えられます。
- D. 顧客の購買傾向データを分析するように訓練されており、サプライヤーのコストデータに関する情報が与えられている。

Answer: B ([メッセージを残す](#))

シラバスでは、トレーニングに使用されたものと同じドメインでの入力の変更は、適応性を持って処理されることが期待されると説明されています。

適応性とは、システムが環境や入力の変化に応じて動作を調整する能力を指します。これには、画像やセンサーデータの解像度の変化など、システムの想定される動作範囲内にある入力の変化も含まれます。(参照ISTQB CT-AIシラバスv1.0、セクション7.6および8.2)

最新問題: 71

AllerEgoは、様々な地形や敵機編隊といった戦闘状況下におけるパイロットの行動を、自己学習を用いて予測する製品です。訓練後、モデルを実世界のデータに曝露したところ、モデルの挙動が不良であることが判明しました。訓練とテストに適した状態にするために、データに対して多数のデータ品質テストが実施されました。

特に AI システムの自己学習の性質を考慮すると、次のオプションのうち、パフォーマンスの低下の考えられる理由として最も適切ではないものはどれですか。

1つのオプションを選択

- A. モデルが受け入れられる前に改善の基準を定義することが難しい。
- B. 変化のペースが速かったため、テストに十分な時間が取れませんでした。
- C. 動作環境の性質が不明であり、仕様が不十分なためにパフォーマンスが低下した可能性があります。
- D. AI システムにはアルゴリズムの偏りがありました。

Answer: A ([メッセージを残す](#))

* A. モデルが受け入れられる前に改善の基準を定義することが難しい。

* 改善基準の定義はAIモデルの受け入れにおいて課題となりますが、実世界のシナリオにおけるパフォーマンスの低下とは直接関係しません。これは、導入後のモデルのリアルタイムパフォーマンスに影響を与えるというよりも、評価と導入段階に関係しています。

* B. 変化のペースが速かったため、テストに十分な時間が取れませんでした。

* これはモデルのパフォーマンスに大きな影響を与える可能性があります。システムが自己学習型の場合、迅速な適応が求められ、テスト時間が不十分だと学習が不完全になり、パフォーマンスが低下する可能性があります。

- * C. 動作環境の性質が不明であり、仕様が不十分なためにパフォーマンスが低下した可能性があります。
 - * これはパフォーマンスに影響を与える可能性が非常に高いです。自己学習型AIシステムは、効果的に適応 学習するために、動作環境の詳細な仕様を必要とします。環境の仕様が不十分な場合、モデルは現実世界のシナリオにおいて正確に動作しない可能性があります。
 - * D. AI システムにはアルゴリズムの偏りがありました。
 - * アルゴリズムのバイアスはAIシステムのパフォーマンスに大きな影響を与える可能性があります。モデルにバイアスが含まれている場合、さまざまなシナリオやデータ分布において良好なパフォーマンスを発揮できません。
- 自己学習の性質とリアルタイムの適応性の必要性を考慮すると、オプション A はリアルタイムのパフォーマンスの問題ではなく受け入れ基準を扱うため、パフォーマンスの低下を説明する可能性は最も低くなります。

Valid CT-AI Dumps shared by GoShiken.com for Helping Passing CT-AI Exam!

GoShiken.com now offer the **newest CT-AI exam dumps**, the GoShiken.com CT-AI exam **questions have been updated** and **answers have been corrected** get the **newest**

GoShiken.com CT-AI dumps with Test Engine here: <https://www.goshiken.com/ISTQB/CT-AI-mondaishu.html> (122 Q&As Dumps, **30%OFF** Special Discount: **Freepdfdumps**)