

Microsoft.AI-300.v2026-07-02.q49

試験コード : AI-300
試験名称 : Operationalizing Machine Learning and Generative AI Solutions
認証ベンダー : Microsoft
無料問題の数 : 49
バージョン : v2026-07-02
ページの閲覧量 : 106
問題集の閲覧量 : 515

<https://www.jpnsiken.com/shiken/Microsoft.AI-300.v2026-07-02.q49.html>

質問: 1

あるチームが、Microsoft Foundryにデプロイされたモデルを使用する生成型AIアプリケーションをデプロイする。

アプリケーションは、本番環境の負荷下でのレイテンシ監視をサポートする必要があります。

パフォーマンスの可観測性を有効にする必要があります。

どの3つの行動を順番に実行すべきでしょうか？回答するには、行動リストから適切な行動を回答欄に移動させ、正しい順序に並べ替えてください。

Set up the model endpoint in Foundry.	
Enable logging.	
Apply a term blocklist.	
Generate token embeddings.	
Configure monitoring metrics.	

正解:

Enable performance observability

Answer Area

Set up the model endpoint in Foundry.
Enable logging.
Apply a term blocklist.
Generate token embeddings.
Configure monitoring metrics.

Set up the model endpoint in Foundry.
Configure monitoring metrics.
Enable logging.

Explanation:

Microsoft の Azure AI Foundry アプリケーション向け可観測性ガイダンスでは、3 段階の有効化手順が説明されています。まず、デプロイ前に Microsoft Foundry プロジェクト設定でトレースを有効にします。トレースは、アプリケーションの LLM 呼び出しを OpenTelemetry 互換のスパンで計測し、フローの各ステップのタイミング データをキャプチャします。次に、アプリケーションを運用エンドポイントにデプロイして、計測対象のコードパスに実際のトラフィックが流れるようにします。実際の運用トラフィックがないと、観測できるレイテンシ データは存在しません。

3つ目は、Azure MonitorとApplication Insightsを構成して、トレーシングによって出力されるテレメトリを受信、集約、視覚化するようにします。Azure MonitorのメトリックエクスプローラーとApplication Insightsのパフォーマンスビューには、p50、p95、p99のレイテンシ分布が時系列で表示されるため、チームはレイテンシの悪化を特定し、アラートのしきい値を設定できます。この一連の手順（計測デプロイ、視覚化）は、Microsoftが推奨する、本番環境におけるAIパフォーマンスの可観測性を実現する標準的な方法です。

Microsoft Learn リファレンス トピック: Azure Monitor と Microsoft Foundry Tracing を使用して生成型 AI アプリケーションを監視する

Enable performance observability	Answer Area
Set up the model endpoint in Foundry.	Set up the model endpoint in Foundry.
Enable logging.	Configure monitoring metrics.
Apply a term blocklist.	Enable logging.
Generate token embeddings.	
Configure monitoring metrics.	

質問: 2

あるチームが、Azure Machine Learningにおける分類ワークフローのために、従来型のモデルを用いた実験を行っている。

チームは、実験中に作成されたアセットを管理するための、一貫した方法を必要としている。

成果物がプロジェクト間で再利用でき、適切に管理されるようにする必要があります。

どの資産を登録すべきですか？

- A. モデル
- B. コンポーネント
- C. 環境
- D. パイプライン

正解: ([正解を表示します](#))

Azure Machine Learning の分類ワークフローでは、モデルを登録する必要があります。

登録を行うと、ワークスペースまたは集中管理レジストリにバージョン管理されたアセットが作成されます。これは、成果物がさまざまなプロジェクトや環境間で再利用可能、管理され、追跡可能であることを保証するために不可欠です。

再利用とガバナンスのための主要資産

一貫性のある統制されたワークフローを維持するためには、以下の特定の資産の登録に重点を置く必要があります。

モデル：主要な成果物。モデルを登録することで、その由来 (どの実験で作成されたか) を追跡し、バージョン管理を行い、複数の環境に一貫してデプロイできるようになります。

コンポーネント：これらは、パイプライン内の特定のステップ (データクリーニング、トレーニングなど) を実行する自己完結型のコードです。これらを登録することで、異なるチームが同じコードを再利用できるようになります。

コードを書き換えることなく、「従来型」の分類ロジックを実現する。

環境：モデルの実行に必要なソフトウェア依存関係 (Pythonパッケージ、Dockerイメージなど) をカプセル化します。これらを登録することで、異なる計算対象間での再現性が確保されます。

データ資産：トレーニング用データセットとテスト用データセットをバージョン管理された資産として登録することで、特定のモデルバージョンのトレーニングに使用されたデータが何であったかを常に正確に監査できるようになります。

参照：

<https://learn.microsoft.com/en-us/azure/machine-learning/concept-azure-machine-learning-v2>

質問: 3

Azure Machine Learning ワークスペースには、運用環境で使用されるモデルの登録済みバージョンが複数含まれています。

旧バージョンのモデルは、もはや展開できないようにする必要がありますが、コンプライアンスレビューやロールバックの可能性に備えて、利用可能な状態にしておく必要があります。

要件を満たすためには、モデルバージョンの状態を変更する必要があります。

あなたはどうすべきでしょうか？

- A. モデルバージョンのトレーニングデータセットをアーカイブします。
- B. モデルバージョンを削除します。
- C. モデルのバージョンをアーカイブします。
- D. モデルバージョンの登録を解除します。

正解: ([正解を表示します](#))

Azure Machine Learning のモデルレジストリは、次の 3 つのライフサイクル状態をサポートしています。アクティブ (デフォルトの、完全に使用可能な状態)、アーカイブ済み (デプロイはできませんが、レビューのためにアクセス可能です)、削除済み (完全に削除されました)。

アーカイブ機能はまさにこのシナリオのために設計されています。運用チームが誤って古いバージョンを選択して新しいデプロイメントを行うことを防ぎつつ、コンプライアンス担当者はアーカイブされたバージョンを検査し、新しいバージョンとのメトリクスを比較し、ロールバックが必要な場合に迅速に再アクティブ化することができます。削除 (オプションB) を選択すると、バージョンが完全に削除され、コンプライアンスレビューとロールバックが不可能になり、両方の要件に違反することになります。登録解除 (オプションD) は標準の Azure ML 操作ではありません。削除は削除操作です。トレーニング データセットのアーカイブ (オプションA) は、モデルバージョンのデプロイ可能性とは関係ありません。アーカイブはデプロイ時にソフト ブロックを作成しますが、アーティファクトの履歴全体は保持されます。

Microsoft Learn リファレンス トピック: Azure Machine Learning レジストリでのモデルバージョンの管理 - アーカイブとライフサイクル管理

質問: 4

機械学習モデルが Azure Machine Learning にデプロイされ、ビジネスアプリケーション向けに予測を生成しています。このモデルは、デプロイ時点で想定される入力パターンを表す過去のデータセットを使用してトレーニングされました。

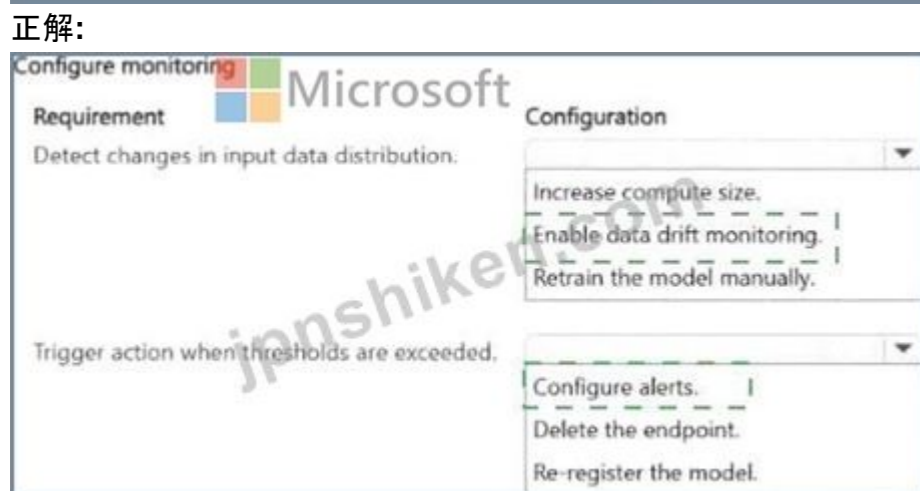
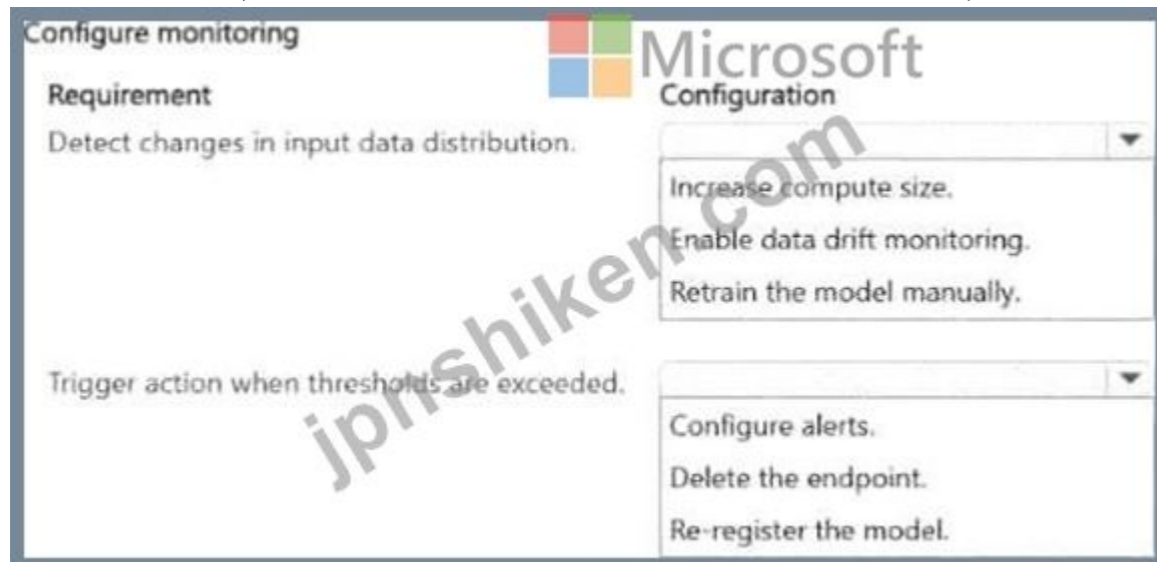
モデル開発チームは、以下の事項を確実に実施しなければならない。

入力データ分布の変化が検出されます。

事前に定義されたしきい値を超えると、適切な措置が講じられます。

要件を満たすように監視システムを設定する必要があります。

各要件に対して、どの構成を使用すべきでしょうか？回答するには、回答欄で適切なオプションを選択してください。注：正解ごとに1ポイントが加算されます。



Explanation:

Azure Machine Learning のデータドリフトモニターは、最初の要件を満たします。ライブ推論入力フィーチャの統計分布をベースラインのトレーニングデータ分布と継続的に比較し、重大なドリフトが発生した場合にフラグを立てます。しきい値を超えた場合に適切なアクションをトリガーするという 2 番目の要件については、ドリフトメトリック

に対して Azure Monitor アラートルールが構成されます。ドリフト係数が定義されたしきい値を超えると、Azure Monitor はアラートを発報し、Logic Apps の起動、メールの送信、Azure ML 再トレーニングパイプラインのトリガー、または Teams への投稿などを実行できます。この 2 層アプローチ (ML 固有のドリフト検出と Azure Monitor アラートによるサポート) は、Microsoft が推奨する運用モデル監視のパターンです。データドリフトモニターが検出を処理し、Azure Monitor が運用上の対応を処理することで、2 つの懸念事項を明確に分離します。

Microsoft Learn リファレンス トピック: モデル データ ドリフトの監視 - Azure Machine Learning モデルの監視と Azure Monitor の統合

Requirement

Detect changes in input data distribution.

Configuration

- Increase compute size.
- Enable data drift monitoring.**
- Retrain the model manually.

Trigger action when thresholds are exceeded.

- Configure alerts.**
- Delete the endpoint.
- Re-register the model.



質問: 5

数百万件のレコードに対して、定期的に大規模な推論ジョブを実行する必要があります。ジョブはレイテンシに敏感ではありませんが、コスト効率が高く、スケーラブルである必要があります。どのデプロイメントオプションが最も適切でしょうか？

- A. マネージドオンラインエンドポイント
- B. バッチエンドポイント
- C. ローカルエンドポイント
- D. ノートブックの実行

正解: ([正解を表示します](#))

バッチエンドポイントは、大規模な非同期推論ワークロード向けに最適化されています。大規模なデータセットを効率的に処理し、需要に応じてスケーリングするため、リアルタイムではないシナリオにおいてコスト効率に優れています。オンラインエンドポイントは、低遅延が求められるユースケース向けに設計されており、バッチ処理においてはコストが高くなります。

質問: 6

あるチームは、共有プロンプトテンプレートを利用する複数の AI アプリケーションを Microsoft Foundry 上で開発している。

チームは、プロジェクト間でプロンプトコンテンツを追跡、バージョン管理、再利用するための集中管理された方法を必要としている。

プロンプトコンテンツを追跡し、再利用するためのソリューションを提案する必要があります。

どちらのアプローチを推奨すべきでしょうか？

- A. プロンプトをバージョン管理されたファイルとして Git リポジトリに保存します。
- B. Azure Machine Learning ワークスペースでプロンプトをデータセットとして登録します。
- C. アプリケーション設定ファイルにプロンプトを直接埋め込む。
- D. フォルダーレベルの整理でプロンプトを Azure Blob Storage に永続化します。

正解: ([正解を表示します](#))

Gitリポジトリは、必要な3つの機能をすべて備えています。変更履歴（作成者情報とタイムスタンプ付き）、実験のためのブランチ機能、安定版リリースのタグ付け機能、そしてクローンまたはサブモジュール参照を介してすべてのプロジェクトからアクセスできる単一の信頼できる情報源です。Azure MLデータセット (オプションB)は、テキスト構成アーティファクトではなく、トレーニングデータ用に設計されており、行ごとの差分追跡やレビューワークフローは備えていません。

アプリケーション構成ファイルにプロンプトを埋め込む方法 (オプションC)では、プロンプトの内容が複数のアプリケーションに分散し、統一されたビュー、共有バージョン管理、プロジェクト間での再利用ができなくなります。フォルダ構成を備えた非構造化Blobストレージ (オプションD)では、バージョン履歴、差分追跡、レビューワークフロー、プロンプトのバリエーションを比較するためのネイティブツールが提供されません。Microsoft Foundryプロジェクト全体でプロンプトの内容を一元的に追跡、バージョン管理、再利用するには、Gitが最適なソリューションです。

Microsoft Learn リファレンス トピック: プロンプト エンジニアリングとバージョン管理 - Git を使用した AI アプリケーションでのプロンプトの管理

質問: 7

データサイエンスチームが、融資承認の結果を予測する分類モデルを訓練する。

モデルを登録する前に、チームは以下の事項を確認する必要があります。

予測は、保護対象グループに不均衡な影響を与えてはならない。

予測誤差は、異なるデータセグメント間で評価することができる。

そのモデルが責任あるAIの期待を満たしているかどうかを評価する必要があります。

どの2つのアプローチを使用すべきですか? 正解はそれぞれ解決策の一部を示しています。注: 正解ごとに1ポイントが加算されます。2つ選択してください。

A. グローバルコホート全体のエラー率を分析する。

B. 負荷がかかった状態でエンドポイントのレイテンシを測定します。

C. 推論スキーマの互換性を検証します。

D. 予測の透明性のために特徴量の重要度を評価する。

E. 定義された人口統計学的コホート全体でエラー率を分析する。

正解: ([正解を表示します](#))

融資承認モデルは、登録前に透明性と人口統計上の公平性の両面から評価されなければならない。

オプションD (特徴量の重要度) は予測の透明性に対応しています。SHAP または Azure ML の責任ある AI ダッシュボードを使用すると、どの特徴量が個々の予測を左右しているかをチームが確認でき、保護対象属性のプロキシ変数が不適切に意思決定に影響を与えているかどうか明らかになります。オプションE (人口統計コホート全体のエラー率) は、モデルが特定のグループに対してより多くの間違いを犯しているかどうかを直接測定します。これは、責任あるAIの原則で要求される公平性の主要な指標です。オプションA (グローバルエラー率) は、コホートレベルの分析が必要なため、格差を隠蔽します。オプションB (エンドポイントのレイテンシ) は、パフォーマンス エンジニアリング上の懸念事項です。オプションC (推論スキーマの互換性) は、技術的な統合チェックです。Azure ML の責任ある AI ダッシュボードは、まさにこのようなデプロイ前の公平性評価のために設計された統合インターフェイスで、エラー分析と特徴量の重要度の両方を組み合わせています。

Microsoft Learn リファレンス トピック: Azure Machine Learning の責任ある AI ダッシュボード - エラー分析とモデルの解釈可能性

質問: 8

あなたは、Microsoft Foundry にデプロイされた、高度に調整された大規模な言語モデルを監視しています。

ファインチューニングの前後で、同じ評価データセットを使用してモデルを評価します。

あなたは以下の評価結果を確認します。

Evaluation metric	Baseline model	Fine-tuned model
Groundedness score	0.82	0.91
Relevance score	0.85	0.88
Hallucination rate	0.06	0.05
Response latency (ms)	420	430

回帰分析を導入せずに、微調整されたモデルのパフォーマンスが向上するかどうかを判断する必要があります。

以下の各設問について、該当する場合は「はい」を選択してください。該当しない場合は「いいえ」を選択してください。注：正解ごとに1点が加算されます。

Fine-tuned model evaluation metrics

Statement	Yes	No
The fine-tuned model shows improved grounding compared to the baseline model.	<input type="radio"/>	<input type="radio"/>
The fine-tuned model introduced a regression in hallucination behavior.	<input type="radio"/>	<input type="radio"/>
The fine-tuned model's response latency indicates a functional failure.	<input type="radio"/>	<input type="radio"/>
The evaluation results indicate that fine-tuning improved overall response quality.	<input type="radio"/>	<input type="radio"/>

正解:

Fine-tuned model evaluation metrics

Statement	Yes	No
The fine-tuned model shows improved grounding compared to the baseline model.	<input checked="" type="radio"/>	<input type="radio"/>
The fine-tuned model introduced a regression in hallucination behavior.	<input type="radio"/>	<input checked="" type="radio"/>
The fine-tuned model's response latency indicates a functional failure.	<input type="radio"/>	<input checked="" type="radio"/>
The evaluation results indicate that fine-tuning improved overall response quality.	<input checked="" type="radio"/>	<input type="radio"/>

Explanation:

同じ評価データセットを使用して、ファインチューニングされたモデルをベースモデルと比較評価する場合、各メトリックの解釈には慎重な分析が必要です。ファインチューニングされたモデルが対象タスクで改善しているという記述は、タスク固有の精度、F1 スコア、または ROUGE スコアなどの対象メトリックが統計的に意味のある改善を示している場合に限り、真となります。補完的なメトリックに対する回帰に関する記述は、ファインチューニングされたモデルのそのメトリックのスコアがベースモデルのスコアよりも意味のあるほど低い場合に真となります。Microsoft Foundry の評価フレームワークでは、ファインチューニング前とファインチューニング後の両方の結果が同じ実験に対して保存されるため、直接並べて比較できます。基本原則は、ファインチューニングによって安全性や一貫性が低下する場合、主要タスクの改善だけでは不十分であるということです。これは壊滅的忘却と呼ばれ、評価データセットはこれを検出できるように設計されています。

Statement	Yes	No
The fine-tuned model shows improved grounding compared to the baseline model.	<input checked="" type="radio"/>	<input type="radio"/>
The fine-tuned model introduced a regression in hallucination behavior.	<input type="radio"/>	<input checked="" type="radio"/>
The fine-tuned model's response latency indicates a functional failure.	<input type="radio"/>	<input checked="" type="radio"/>
The evaluation results indicate that fine-tuning improved overall response quality.	<input checked="" type="radio"/>	<input type="radio"/>

質問: 9

注 :この問題は、同じシナリオを提示する一連の問題の一部です。このシリーズの各問題には、提示された目標を満たす可能性のある独自の解答が含まれています。問題セットによっては、複数の正解がある場合もあれば、正解がない場合もあります。

このセクションの質問に回答すると、後から戻って回答することはできません。そのため、これらの質問は復習画面には表示されません。

Microsoft Foundryでは、プロンプトフローに沿って作業を進めます。

プロンプトは手動で評価し、プロンプトのバリエーション間で結果を比較する必要があります。

評価のためには、各フロー実行における入力、出力、トークン使用量、および遅延時間を記録する必要があります。

解決策 :プロンプトフローSDKを使用して、フローを実行する前にトレースを有効にします。その後、フローを実行してトレース可能な結果を生成します。

その解決策は目標を達成しているか？

A. はい

B. いいえ

正解: [\(正解を表示します\)](#)

プロンプト フロー SDK のみを使用してトレースを有効にするだけでは、必要な 4 つのディメンション (入力、出力、トークンの使用状況、レイテンシ) すべてがキャプチャされ、Microsoft Foundry ポータルのトレース ビューアに表示されることが保証されません。これにより、実行間で手動で比較できるようになります。プロンプト フロー SDK はトレース構成をサポートしていますが、この特定のキャプチャ要件を満たすための完全なサポート対象パスは、ポータル ベースのトレースの有効化です。このシリーズの次の質問で確認されているように、正しい完全な解決策は、Microsoft Foundry ポータルでプロジェクトのトレース トグルを直接使用し、テスト実行を実行することです。このポータル側のトレース機能は、4 つのディメンションすべてを計測し、Foundry インターフェイスからアクセスできるクエリ可能なトレース ストアに保存するように特別に設計されています。

Microsoft Learn リファレンス トピック: Microsoft Foundry ポータルでプロンプト フローのトレースを有効にする - 実行テレメトリの取得

質問: 10

注 :この問題は、同じシナリオを提示する一連の問題の一部です。このシリーズの各問題には、提示された目標を満たす可能性のある独自の解答が含まれています。問題セットによっては、複数の正解がある場合もあれば、正解がない場合もあります。

このセクションの質問に回答すると、後から戻って回答することはできません。そのため、これらの質問は復習画面には表示されません。

Microsoft Foundryでは、プロンプトフローに沿って作業を進めます。

プロンプトは手動で評価し、プロンプトのバリエーション間で結果を比較する必要があります。

評価のためには、各フロー実行における入力、出力、トークン使用量、および遅延時間を記録する必要があります。

解決策 : プロンプトフローSDKを使用して、フローを実行する前にトレースを有効にします。その後、フローを実行してトレース可能な結果を生成します。

その解決策は目標を達成しているか？

A. はい

B. いいえ

正解: ([正解を表示します](#))

正しい :

* Microsoft Foundry で、プロジェクトのプロンプト フローのトレースを有効にし、テスト ランを実行してトレース データを生成します。

正しくない :

* 評価エクスペリエンスでプロンプトのバリエーションを作成し、その出力を比較します。

* 実行前にプロンプトフローSDKを使用してフローのトレースを有効にします。その後、フローを実行してトレース可能な結果を生成します。

注記 :

Azure AI Foundry では、トレースを有効にして一括テスト機能を使用することで、これらのメトリックを取得して比較できます。これにより、共通のデータセットに対して、さまざまなプロンプトのバリエーションを体系的に評価できます。

プロンプトのバリエーションを評価および比較する手順

*-> 1. トレースを有効にする

Prompt Flowプロジェクトに移動してください。

フロー作成ページの上部にある「トレース」トグルを探してください。

オンに切り替えてください。

これにより、すべての実行において、レイテンシ、トークン数、およびノードレベルの入出力が確実に記録されます。

2. プロンプトのバリエーションを作成する

フロー内で、テストしたいLLMノードを特定します。

「バリエーション」をクリックすると、プロンプトの複数のバージョンを作成できます (例Variant_0、Variant_1)。

これにより、異なる指示や少数のサンプルを並べてテストすることができます。

3. 一括テスト (評価を実行する)

4. 結果を分析する

参照 :

<https://www.linkedin.com/pulse/streamlining-generative-ai-development-azure-foundry-tracing-taneja-mbwze>

質問: 11

Python SDK v2 を使用して、workspace1 という名前の Azure Machine Learning ワークスペースを管理します。mlstorage 1 という名前の汎用 v2 Azure ストレージ アカウントを作成します。このストレージ アカウントには、mlcontainer 1 という名前のパブリック アクセス可能なコンテナが含まれています。このコンテナには、CSV 形式のファイルを含む 10 個のブロッブが格納されています。

mlcontainer 1 という名前のコンテナ内のすべてのブロッブを参照するデータアセットを作成するには、Python SDK v2 コードを開発する必要があります。

Python SDK v2のコードを完成させる必要があります。

コードを完成させるにはどうすればよいでしょうか？回答するには、回答欄で適切なオプションを選択してください。注 :

正解ごとに1ポイント獲得できます。

VIEWER AREA

```
sample_dataset = Data(  
  path= ://mlstorage1.blob.core.windows.net/mlcontainer'
```



wasbs

abfss

azureml

```
type=AssetTypes.
```

URI_FILE

URI_FOLDER

URI_MLTABLE


```
description="sample_dataset",  
name="sample_dataset",  
version='1.0'
```

正解:

```
Answer Area
sample_dataset = Data(
  path= [dropdown menu] ://mlstorage1.blob.core.windows.net/mlcontainer1,
  type=AssetTypes. [dropdown menu]
  description="sample_dataset",
  name="sample_dataset",
  version='1.0'
)
```

Dropdown menu for path: wasbs, abfss, azureml

Dropdown menu for type: URI_FILE, URI_FOLDER, URI_MLTABLE



Explanation:

単一のファイルではなく、コンテナ内のすべてのblobを参照したいので、適切なアセットタイプは AssetTypes.URI_FOLDER です。このタイプはディレクトリレベルの URI を指し、Azure ML がその内部のすべてのファイルを走査できるようにします。パブリックにアクセス可能な Azure Blob Storage コンテナの場合、URI は次のパターンに従います。

https://storage_account.blob.core.windows.net/container_name/。次に、正しいタイプ、パス、名前、およびバージョンパラメータを使用してデータオブジェクトを作成し、ml_client.dataを使用してワークスペースに登録します。

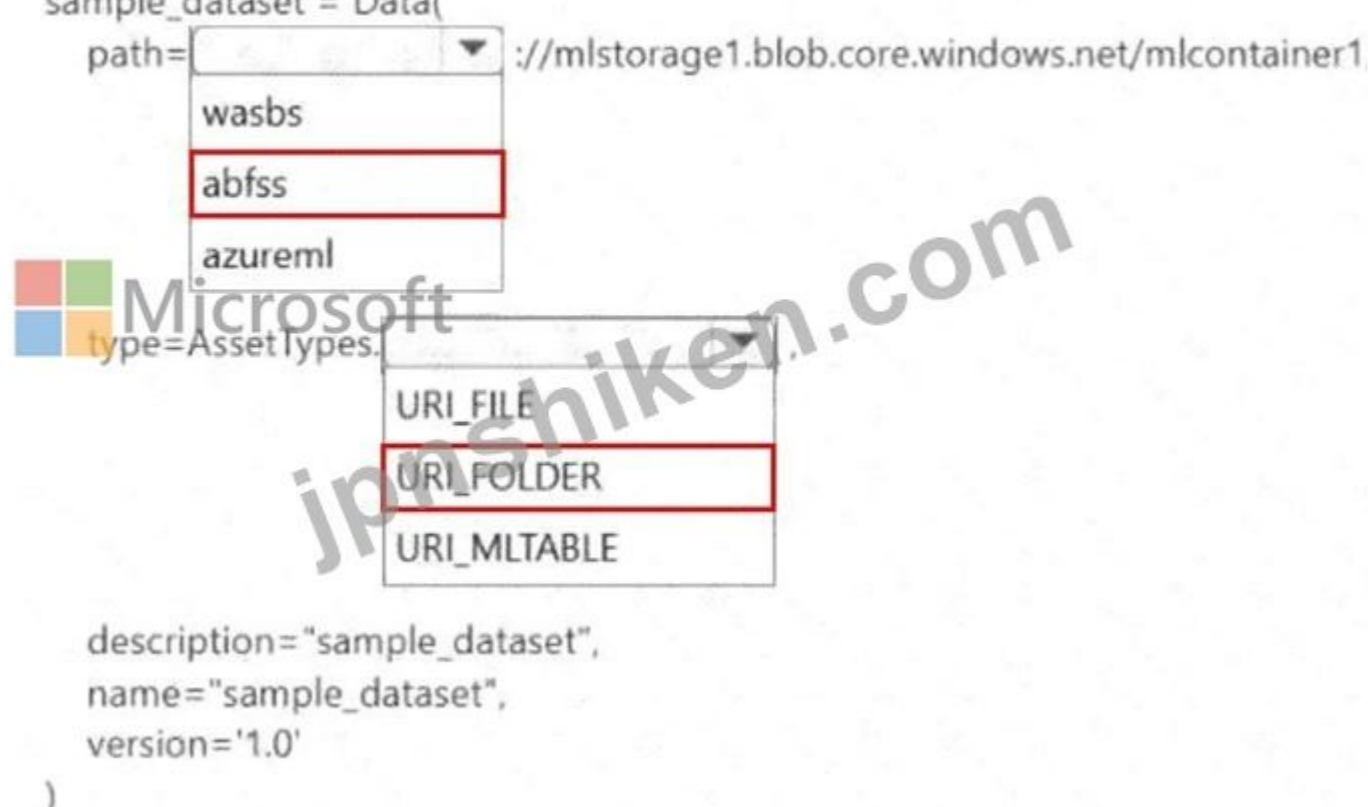
create_or_update。単一のファイルを参照する AssetTypes.URI_FILE は使用しないでください。AssetTypes は使用しないでください。

MLTable YAML 記述子がない限り、MLTABLE を使用してください。Azure Blob Storage コンテナ内の CSV blob のコレクションを参照するには、URI_FOLDER が適切な選択肢です。これにより、Azure ML は指定されたパス内のすべてのファイルを検出して処理できます。

Microsoft Learn リファレンス トピック: Azure Machine Learning Python SDK v2 でデータ資産を作成および管理する - URI_FOLDER

Answer Area

```
sample_dataset = Data(  
  path= ://mlstorage1.blob.core.windows.net/mlcontainer1  
  type=Asset types.  
  description="sample_dataset",  
  name="sample_dataset",  
  version='1.0'  
)
```



質問: 12

顧客からのフィードバックを分析するために、基本言語モデルを微調整しています。

サポートチケットの例にラベルを付けます。Microsoft Foundry で基本モデルを構成および微調整することで、分類精度を向上させる必要があります。

設定を行い、微調整を実行する必要があります。

まず最初に何をすべきでしょうか？

- A. プロンプトフローを使用して、評価用の複数のプロンプトテンプレートを生成します。
- B. 微調整を開始する前に、ベースモデルをオンラインエンドポイントにデプロイします。
- C. 評価パイプライン内のすべての推論呼び出しのトレースを有効にします。
- D. データセットをプロンプトと補完のペアを含む JSONL ファイルとしてフォーマットし、ファイルをアップロードします。

正解: C ([コメントを公表する](#))

Microsoft Foundry では、顧客からのフィードバックを分析するための微調整ジョブ (サポートチケットの分類など) を構成および実行する際に、まず評価パイプライン内のすべての推論呼び出しのトレースを有効にする必要があります。

トレースは、ファインチューニングワークフローの「評価」フェーズにおける重要なステップであり、入力/出力例の取得、分類エラーの根本原因の特定、レイテンシの監視、トレーニング前後のモデルの動作分析を可能にします。

注記:

モデルを微調整し、効果的に評価するには、以下の手順に従ってください。

1. 初期ベースラインのトレースを有効にする

微調整を行う前に、既存の評価パイプライン内のすべての推論呼び出しに対してトレースを有効にする必要があります。

目的: これにより、基本モデルが現在どのように機能不全に陥っているかを明確に示す「記録」を作成する。

利点 :トレース機能により、入力、出力、および中間ステップが正確に記録されます。これらのトレースを分析することで、精度が低い原因が、モデルが指示に従っていない、ドメイン固有の専門用語が欠落している、または特定のチケットカテゴリに対応できていないなど、どのようなものかを特定できます。

設定 :Foundryで自動トレース（現在プレビュー版）を有効にすると、コードを変更することなくこれらの詳細をApplication Insightsにログ記録できます。

2. 微調整の設定と実行

トレースを分析し、ラベル付きデータセットを準備したら、微調整作業に進むことができます。

3. 継続的な評価

作業が完了したら、微調整したモデルを元のトレースと比較する必要があります。参照:

<https://devblogs.microsoft.com/foundry/a-developers-guide-to-fine-tuning-gpt-4o-for-image-classification-on-azure-ai-foundry>

質問: 13

ある金融サービス会社は、規制対象の顧客データを処理する生成型AIワークロードをホストするために、Microsoft Foundryを導入しています。Microsoft Foundry環境は、Microsoft Foundryによって管理されるサービスが依存するAzureリソースと通信できるようにしつつ、パブリックネットワークへの露出を一切防ぐ必要があります。セキュリティ監査担当者は、Microsoft Foundryリソースとの間のすべてのトラフィックはプライベートネットワーク内で行われ、パブリックエンドポイントは一切利用できないことを要求しています。

Microsoft Foundry環境を構成して、プラットフォームの機能を完全に維持しつつ、ネットワークアクセスを制限する必要があります。

どの2つの行動をとるべきでしょうか？それぞれの正解は、解決策の一部を示しています。

2つ選択してください。

注：正解ごとに1ポイントが加算されます。

- A. Microsoft Foundry リソース用のマネージド仮想ネットワークを構成します。
- B. すべてのモデルエンドポイントにAPIキー認証を使用します。
- C. Microsoft Foundry リソースを別の Azure サブスクリプションにデプロイします。
- D. Microsoft Foundry リソースへのパブリック ネットワーク アクセスを無効にします。
- E. すべての受信ネットワークアクセスを無効にします。

正解: **A,E** ([コメントを发表する](#))

生成型AIワークロードを、完全にプライベートな通信のみでパブリックネットワークに公開しないMicrosoft Foundry環境でホストするには、特定の分離設定を持つマネージド仮想ネットワーク (マネージドVNet)を構成し、すべてのパブリック受信アクセスを無効にする必要があります。

[A]

マネージド仮想ネットワーク分離を有効にする

Azure AI Foundry ハブを作成する際に、[ネットワーク] タブに移動してください。

「承認済み送信プライベート」分離モードを選択してください。このモードでは、管理対象のコンピューティング リソースからのすべての送信トラフィックが、依存する Azure リソースなど、明示的に承認した宛先のみで制限されます。

一度有効にした隔離モードは無効にできません。

[そして]

パブリック受信アクセスを無効にする

Foundryリソースの「ネットワーク」タブで、「パブリックネットワークアクセス」を「無効」に設定します。

この措置により、公共インターネットからのすべてのトラフィックが遮断され、リソースへのアクセスはプライベート接続経由でのみ可能になります。

参照：

<https://learn.microsoft.com/en-us/azure/foundry/how-to/managed-virtual-network>

質問: 14

チームは、管理対象のオンラインエンドポイントに機械学習モデルをデプロイします。チームは、本番環境におけるモデルのパフォーマンスとデータ品質の指標を監視します。監視しきい値を超えた場合、チームは下流システムに通知する自動化された運用対応を必要としている。

要件を満たすように監視ソリューションを設定する必要があります。

まず、各要件にどの構成を関連付けるべきでしょうか？回答するには、適切な構成を正しい要件に移動してください。各構成は、1回、複数回、またはまったく使用しない場合があります。コンテンツを表示するには、ペイン間の分割バーを移動したり、スクロールしたりする必要がある場合があります。注：正解ごとに1ポイントが加算されます。

Configurations

Enable autoscaling.

Trigger retraining pipeline.

Configure alert rules.

Configure a performance monitoring solution

Requirement

Configuration

Automated response

Infrastructure optimization

正解:

Explanation:

Microsoft の Azure Machine Learning モデル監視に関するドキュメントでは、階層化されたアラート アーキテクチャについて説明しています。ベース レイヤーでは、Azure ML モデルが計算ドリフト、予測、およびデータ品質メトリックを定期的に監視し、結果を Azure Monitor メトリックとして公開します。関係者に通知するには、これらのメトリックを監視し、しきい値を超えたときにアクショングループを実行する Azure Monitor アラート ルールを作成します。

アクショングループは、電子メール、SMS、プッシュ通知、および Webhook 呼び出しをサポートします。自動再トレーニングを開始するには、アクショングループ内の Webhook 呼び出しが Azure ML パイプラインの REST エンドポイントをターゲットにし、再トレーニングの実行をトリガーします。または、AML ワークスペース イベントの Azure Event Grid サブスクリプションを使用して、モデル品質イベントをパイプラインを開始する Azure Functions にルーティングすることもできます。監視、アラート、通知、および修復が分離されているのは意図的なものであり、各コンポーネントを個別に更新できます。

Microsoft Learn リファレンス トピック: データとモデルの品質に関するモデル監視の設定 - Azure Machine Learning モデル監視

Configurations

Enable autoscaling.

Trigger retraining pipeline.

Configure alert rules.

Configure a performance monitoring solution

Requirement

Automated response

Infrastructure optimization



Configure alert rules.

Trigger retraining pipeline.

質問: 15

ケーススタディ1 - ファブリカム社

背景

Fabrikam Inc.は、米国全土の地域病院システムに対し、人口健康ダッシュボードと予測分析を提供する中規模のヘルスケア分析企業です。

Fabrikam Inc.の顧客は、患者の流れ、人員配置のニーズ、再入院リスクを監視するために、ほぼリアルタイムの分析を活用しています。彼らは、予測のために複数の従来型の予測機械学習モデルを使用しています。

Fabrikam Inc.は既にMicrosoft Azureを基盤として運用しています。同社は、ローカルサーバー上で動作するJupyter Notebookを主要な開発環境として使用しています。しかし、データサイエンスチームは、現在の開発プラットフォームにおいて、スケーラビリティ、資産管理、コード管理に関する課題に直面しています。Fabrikam Inc.は、これらの課題を解消するため、クラウドベースの開発環境への移行を計画しています。

さらに、同社は顧客サポート向けに、検索拡張生成 (RAG) ベースのチャットアプリケーションを導入する予定です。経営陣は、運用リスクを低く抑えながらアプリケーションを開発・展開することを求めています。

現在の環境

Fabrikam Inc.は、以下のコンポーネントを含む単一のAzureサブスクリプションを運用しています。

- * 匿名化された臨床データセットおよび運用データセットを含むAzure Data Lake Storage Gen2
- * Azure AI Search は、厳選された分析ドキュメントと参考資料をインデックス化します。
- * データサイエンティストが管理する、Pythonベースの小規模なトレーニングスクリプト群
- * 基盤となるモデルがデプロイされたAzure OpenAIサービス
- * RAGベースのソリューションを構築するためのMicrosoft Foundryリソース

評価データには、手動で定義された期待される反応が含まれています。

データサイエンスチームが現在直面している課題は以下のとおりです。

- * モデル学習ジョブは、ノートブックから手動で実行されます。
- * 実験の追跡が不規則です
- * モデルのバージョンは、標準化されたメタデータなしで登録されます。
- * デプロイはデータサイエンティストが手動で行い、ロールバック機能は限定的です。
- * チームには、生成型AIの出力に関する標準化された評価プロセスがありません。

現在の環境では、パブリックネットワークへのアクセスが許可されています。認証は、管理されたIDではなく、ユーザーアカウントに依存しています。計算ターゲットは手動で作成され、複数の実験で共有されています。このため、ピーク使用時にリソースの競合が発生しています。

ビジネス要件

Fabrikam Inc.は、近代化イニシアチブに関して以下のビジネス要件を掲げています。

内部文書やデータセットを使用して、分析に関する質問に答える対話型インターフェースを提供する。

- * 機密性の高い医療関連データが、Fabrikam Inc.のAzureテナント外に公開されないようにしてください。

- * 再現性と監査可能性を備えたモデルのトレーニングおよびデプロイプロセスを可能にする。
- * プロンプト戦略と微調整されたモデルを比較するための実験を支援する。
- * モデルをランク付けされた嗜好に合わせて調整し、長期的な行動を最適化する。
導入期間中、既存の分析ワークロードへの影響を最小限に抑える。

技術要件

事業目標を支援するため、Fabrikam Inc.は以下の技術要件を特定しました。

- * Azure Machine Learningワークスペースを使用して、データ資産、モデル、および環境を一元的に管理します。
- * すべてのトレーニングジョブに対して、実験追跡とモデルのバージョン管理を実装する。

手動でノートブックを実行するのではなく、パイプラインを使用してトレーニングと評価をオーケストレーションします。

- * 段階的なロールアウトとロールバックをサポートする、従来型の機械学習モデルをデプロイします。
- * RAGベースのソリューション出力品質を向上させる。
- * 入出力ペアを含む実データに基づいた既存の評価データセットを使用する。

* 迅速なエンジニアリングでは不十分な場合にのみ、高度な微調整技術を適用します。課題と制約 Fabrikam Inc. は、ネットワーク アクセスを制限し、長期間秘密を保持することを避けることを要求する社内セキュリティ ポリシーを遵守する必要があります。データサイエンス チームは Azure DevOps の経験が限られているため、ソリューションはカスタム インフラストラクチャよりもマネージド サービスと自動化を優先する必要があります。

コスト予測可能性は重要です。経営陣は可能な限りサーバーレスまたはマネージドコンピューティングオプションを好みますが、安定した本番ワークロードに対しては専用コンピューティングも承認する用意があります。

問題提起

Fabrikam Inc.は、生成型AIモデルの信頼性の高いトレーニング、評価、デプロイ、および反復を可能にするAzureベースのAI運用ソリューションを設計および実装する必要があります。このソリューションは、ガバナンス、セキュリティ、および運用上の安定性を確保しながら、実験と段階的な展開をサポートする必要があります。データサイエンス チームとプラットフォームチームは、Azure Machine LearningとMicrosoft Foundryの機能を活用して、このソリューションを実現するために協力する必要があります。

Fabrikam Inc.の課題、制約、および技術要件に対応するためには、コストを意識しつつ、トレーニングのワークロードを分離する必要があります。具体的にどのような対策を講じるべきでしょうか？

- A. 単一の共有コンピューティングクラスタ上で実行されるトレーニングジョブ
- B. 固定サイズの計算クラスタ
- C. 実験ごとに専用の計算クラスタを用意
- D. 自動スケーリング機能を備えたマネージドコンピューティングターゲット

正解: **D** ([コメントを发表する](#))

シナリオ : 課題と制約 :コストの予測可能性が重要です。経営陣は可能な限りサーバーレスまたはマネージドコンピューティングオプションを好みますが、安定した本番ワークロードに対しては専用コンピューティングを承認する用意があります。

自動スケーリング機能を備えたマネージドコンピューティングターゲットは、サーバーレスまたはマネージドオプションが好まれ、コストの予測可能性が重要な場合、Azure Machine Learningのトレーニングワークロードに最適な選択肢です。

最適な実装方法 :オートスケーリング機能を備えたマネージドコンピューティング

このオプション、特にAzure Machine Learningコンピューティングクラスター (AmlCompute)を使用する方法は、お客様のすべての要件を満たしています。

マネージドインフラストラクチャ :Azureは仮想マシンの作成、パッチ適用、ライフサイクル管理を担うため、管理の手間が軽減されます。

コスト予測可能性と効率性 :オートスケーリングでは、最小ノード数をゼロに設定できます。これにより、ジョブの実行中のみコンピューティング料金が発生し、アイドル状態のリソースによるコストを削減できます。

拡張性 :大規模なデータセットや分散トレーニングジョブを処理するために、マルチノードクラスタに自動的にスケールアップできます。

エンタープライズガバナンス :管理者は、サブスクリプションまたはワークスペースレベルでクォータを設定することで、コスト管理を徹底できます。

参照 :

<https://learn.microsoft.com/en-us/azure/machine-learning/how-to-use-serverless-compute>

質問: 16

あるチームが、Microsoft Foundry上に構築された生成型AIアプリケーションで使用されるプロンプトを管理しています。複数の開発者がプロンプトの更新に貢献しており、変更内容は継続的にレビューおよび追跡する必要があります。

チームは以下のことを求めている。

迅速な変更は、本番環境のバージョンに適用する前にレビューされます。

問題が発生した場合、以前のプロンプトバージョンを復元できます。

迅速なアップデートは、アプリケーションコードと同様のガバナンス慣行に従います。

本番環境におけるプロンプトの管理と更新には、統制されたプロセスを導入する必要があります。

要件を満たすために、迅速な更新をどのように管理すればよいでしょうか？回答するには、適切なアクションを正しい要件に移動してください。各アクションは、1回、複数回、またはまったく使用しない場合があります。コンテンツを表示するには、ペイン間の分割バーを移動したり、スクロールしたりする必要がある場合があります。注：正解ごとに1ポイントが加算されます。

ACTIONS

ACTIONS	Requirement	Action
Store prompts in a Git repository.	Track changes and maintain history.	
Use gated pull requests for prompt changes.	Review updates before production use.	
Use a prior agent version.	Roll back to a specific prompt version.	
Update prompts directly in production.		

正解:

ACTIONS

ACTIONS	Requirement	Action
Store prompts in a Git repository.	Track changes and maintain history.	Store prompts in a Git repository.
Use gated pull requests for prompt changes.	Review updates before production use.	Use gated pull requests for prompt changes.
Use a prior agent version.	Roll back to a specific prompt version.	Use a prior agent version.
Update prompts directly in production.		

Explanation:

これら3つの要件はすべて、基盤となるメカニズムとしてGitを指し示していますが、それぞれ異なるGit機能を使用しています。本番環境へのリリース前に変更をレビューする場合 : ブランチベースのワークフローでは、機能ブランチでプロンプト変更を行い、プルリクエストの承認後にのみメインブランチにマージすることで、レビューゲートが強制されます。以前のバージョンを復元する場合 : Gitのコミット履歴とタグシステムは、すべてのプロンプト状態の正確で不変の記録を提供し、git revertまたは特定のコミットSHAへのチェックアウトによって、以前のバージョンを即座に復元できます。

アプリケーションコードとのガバナンスの整合性を保つため、プロンプトをアプリケーションコードと同じGitリポジトリに保存することで、CI/CD、ブランチ保護、コードレビュー、監査ログといったすべてのポリシーが自動的に適用されます。Blobストレージや埋め込み構成ファイルなどの代替手段では、ネイティブなレビューワークフロー、ブランチ保護、完全な監査履歴が利用できません。

Microsoft Learn リファレンス トピック: Microsoft Foundry での Git 統合によるプロンプトの管理とバージョン管理

Actions	Manage prompt updates	Requirement	Action
Store prompts in a Git repository.		Track changes and maintain history.	Store prompts in a Git repository.
Use gated pull requests for prompt changes.		Review updates before production use.	Use gated pull requests for prompt changes.
Use a prior agent version.		Roll back to a specific prompt version.	Use a prior agent version.
Update prompts directly in production.			

有効的なAI-300問題集はJPNTest.com提供され、AI-300試験に合格することに役に立ちます！JPNTest.comは今最新AI-300試験問題集を提供します。JPNTest.com AI-300試験問題集はもう更新されました。ここでAI-300問題集のテストエンジンを手に入れます。最新版のアクセス、<https://www.jpntest.com/shiken/AI-300-mondaishu> 126問、30%ディスカウント、特別な割引コード: **JPNshiken**」

質問: 17

パイプラインのステップが、一時的な計算問題により断続的に失敗します。コアロジックを変更したり、コストを大幅に増加させたりすることなく、信頼性を向上させる必要があります。最適なアプローチは何でしょうか？

- A. 計算サイズを増やす
- B. パイプラインステップで再試行ポリシーを有効にする
- C. パイプラインを手動で実行する
- D. 失敗したステップを削除する

正解: [\(正解を表示します\)](#)

再試行ポリシーにより、パイプラインの各ステップは、一時的なコンピューティング障害やネットワーク障害などの一時的な障害から自動的に復旧できます。これにより、コアロジックを変更したり、インフラストラクチャのコストを増加させたりすることなく、信頼性が向上します。コンピューティングリソースを増やすだけでは、一時的な障害シナリオに効果的に対処することはできません。

質問: 18

ある金融サービス会社は、規制対象の顧客データを処理する生成型AIワークロードをホストするために、Microsoft Foundryを導入しています。Microsoft Foundry環境は、Microsoft Foundryによって管理されるサービスが依存するAzureリソースと通信できるようにしつつ、パブリックネットワークへの露出を一切防ぐ必要があります。セキュリティ監査担当者は、Microsoft Foundryリソースとの間のすべてのトラフィックはプライベートネットワーク内で行われ、パブリックエンドポイントは一切利用できないことを要求しています。

Microsoft Foundry環境を構成して、プラットフォームの機能を完全に維持しつつ、ネットワークアクセスを制限する必要があります。

どの2つのアクションを実行すべきですか？ 正解はそれぞれ解決策の一部を示しています。注: 正解ごとに1ポイントが加算されます。2つ選択してください。

- A. Microsoft Foundry リソース用のマネージド仮想ネットワークを構成します。
- B. すべてのモデルエンドポイントにAPIキー認証を使用します。
- C. Microsoft Foundry リソースを別の Azure サブスクリプションにデプロイします。
- D. Microsoft Foundry リソースへのパブリック ネットワーク アクセスを無効にします。
- E. すべての受信ネットワークアクセスを無効にします。

正解: **A,E** [\(コメントを发表する\)](#)

Microsoft の Azure AI Foundry のドキュメントでは、完全なプライベート ネットワーク分離を実現するために必要な 2 つの構成について説明しています。まず、Foundry リソース用にマネージド仮想ネットワークを構成します。これにより、すべての内部サービス通信をカプセル化する Microsoft マネージド VNet がプロビジョニングされます。Foundry コントロール プレーンは、このマネージド VNet 内のプライベート エンドポイントを介して、ストレージ、キー コンテナー、コグニティブ サービスなどの依存する Azure サービスと通信するため、トラフィックがパブリック インターネットを通過することはありません。次に、Foundry リソースへのパブリック ネットワーク アクセスを無効にします。これにより、パブリック エンドポイントが完全に削除され、承認されたプライベート ネットワーク上のクライアントのみがプライベート エンドポイント接続を介してアクセスできるようになります。これら 2 つのアクションにより、すべてのトラフィックがパブリック エンドポイントのないプライベート ネットワーク上に留まり、セキュリティ監査担当者が求める完全なネットワーク分離の要件を満たします。

Microsoft Learn リファレンス トピック: Azure AI Foundry 用のマネージド仮想ネットワークの構成 - ネットワーク分離とプライベート エンドポイント

質問: 19

ドラッグアンドドロップ問題

あるチームが、Microsoft Foundry上に構築された生成型AIアプリケーションで使用されるプロンプトを管理している。

複数の開発者が迅速なアップデートを提供し、変更点は継続的にレビューおよび追跡する必要があります。

チームは以下のことを求めている。

- プロンプトの変更は、バージョンに適用する前にレビューされます。

生産。

問題が発生した場合は、以前のプロンプトバージョンを復元できます。

- 迅速なアップデートは、アプリケーションコード。

本番環境におけるプロンプトの管理と更新には、統制されたプロセスを導入する必要があります。

要件を満たすために、迅速な更新をどのように管理すればよいでしょうか？回答するには、適切なアクションを正しい要件に移動してください。各アクションは、1回、複数回、またはまったく使用しない場合があります。コンテンツを表示するには、ペイン間の分割バーを移動したり、スクロールしたりする必要がある場合があります。

注：正解ごとに1ポイントが加算されます。

正解:

質問: 20

チームがAzure Machine Learningワークスペースを管理し、エンドポイントにモデルをデプロイします。

展開済みのオンラインエンドポイントは、トラフィックが多い時間帯に応答時間が不安定になる。

潜在的なパフォーマンス低下を特定する必要があります。

監視すべき3つの指標はどれですか？正解はそれぞれ解決策の一部を示しています。注：正解ごとに1ポイントが加算されます。3つ選択してください。

- A. 機能数
- B. 1分あたりのリクエスト数
- C. 接続がアクティブです
- D. データセットのサイズ
- E. リクエスト遅延

正解: ([正解を表示します](#))

トラフィックが多い場合、エンドポイントが需要に対応できているかどうかが問題となります。1分あたりのリクエスト数 (B) は、エンドポイントにかかる実際のリクエスト負荷を示し、トラフィックの急増とパフォーマンスの低下を関連付けることができます。

アクティブな接続数 (C) は、エンドポイントの接続プールが飽和状態にあるかどうかを示します。適切なスケーリングなしに同時接続が多すぎると、キューイングやタイムアウトが発生します。リクエスト遅延 (E) は、ユーザーが体感するパフォーマンスの標準的な指標です。負荷がかかった状態で遅延が増加すると、パフォーマンスの低下が最も明確に示されます。特徴量数 (A) は、実行時パフォーマンスの指標ではなく、モデル設計属性です。データセットサイズ (D) は、エンドポイントのパフォーマンスとは関係のないトレーニング時の懸念事項です。Azure Machine Learning のオンラインエンドポイントは、これらのメトリックを Azure Monitor を通じて公開します。Microsoft は、すべての運用エンドポイントに対して、遅延とリクエストレートのしきい値に関するアラートルールを設定することを推奨しています。

Microsoft Learn リファレンス トピック: Azure Machine Learning オンライン エンドポイントの監視 - マネージド エンドポイントの Azure Monitor メトリック

質問: 21

ホットスポットに関する質問

ある企業が、長時間の会議議事録を要約し、アクションアイテムを抽出する社内ツールを開発している。

モデルは以下の条件を満たす必要があります。

最大20万トークンまでのテキスト入力を処理します。

簡潔な要約を数秒で生成します。

アプリへの統合前に、インタラクティブなテストをサポートする。

低遅延で要約処理をサポートするモデルを選択、展開、テストする必要があります。

構成計画はどのように作成すればよいですか？回答するには、回答欄で適切なオプションを選択してください。

注：正解ごとに1ポイントが加算されます。

Deploying and testing models for summarization

Requirement

Select a model.

Tool

Whisper
Phi-3-Mini
GPT-4.1-Mini
Text-Embedding-Ada-002

Select a deployment type.

Batch endpoint
Custom container
Serverless endpoint
Managed real-time (online) endpoint

Test the model.

Prompt flow
Microsoft Foundry Chat playground
Microsoft Foundry model comparison

正解:

Deploying and testing models for summarization

Requirement

Select a model.

Whisper
Phi-3-Mini
GPT-4.1-Mini
Text-Embedding-Ada-002

Select a deployment type.

Batch endpoint
Custom container
Serverless endpoint
Managed real-time (online) endpoint

Test the model.

Prompt flow
Microsoft Foundry Chat playground
Microsoft Foundry model comparison

質問: 22

ケーススタディ1 - ファブリカム社

背景

Fabrikam Inc.は、米国全土の地域病院システムに対し、人口健康ダッシュボードと予測分析を提供する中規模のヘルスケア分析企業です。

Fabrikam Inc.の顧客は、患者の流れ、人員配置のニーズ、再入院リスクを監視するために、ほぼリアルタイムの分析を活用しています。彼らは、予測のために複数の従来型の予測機械学習モデルを使用しています。

Fabrikam Inc.は既にMicrosoft Azureを基盤として運用しています。同社は、ローカルサーバー上で動作するJupyter Notebookを主要な開発環境として使用しています。しかし、データサイエンスチームは、現在の開発プラットフォームにおいて、スケーラビリティ、資産管理、コード管理に関する課題に直面しています。Fabrikam Inc.は、これらの課題を解消するため、クラウドベースの開発環境への移行を計画しています。

さらに、同社は顧客サポート向けに、検索拡張生成 (RAG) ベースのチャットアプリケーションを導入する予定です。経営陣は、運用リスクを低く抑えながらアプリケーションを開発・展開することを求めています。

現在の環境

Fabrikam Inc.は、以下のコンポーネントを含む単一のAzureサブスクリプションを運用しています。

- * 匿名化された臨床データセットおよび運用データセットを含むAzure Data Lake Storage Gen2
- * Azure AI Search は、厳選された分析ドキュメントと参考資料をインデックス化します。
- * データサイエンティストが管理する、Pythonベースの小規模なトレーニングスクリプト群

- * 基盤となるモデルがデプロイされたAzure OpenAIサービス
- * RAGベースのソリューションを構築するためのMicrosoft Foundryリソース

評価データには、手動で定義された期待される反応が含まれています。
データサイエンスチームが現在直面している課題は以下のとおりです。

- * モデル学習ジョブは、ノートブックから手動で実行されます。
- * 実験の追跡が不規則です
- * モデルのバージョンは、標準化されたメタデータなしで登録されます。
- * デプロイはデータサイエンティストが手動で行い、ロールバック機能は限定的です。
- * チームには、生成型AIの出力に関する標準化された評価プロセスがありません。

現在の環境では、パブリックネットワークへのアクセスが許可されています。認証は、管理されたIDではなく、ユーザーアカウントに依存しています。計算ターゲットは手動で作成され、複数の実験で共有されています。このため、ピーク使用時にリソースの競合が発生しています。

ビジネス要件

Fabrikam Inc.は、近代化イニシアチブに関して以下のビジネス要件を掲げています。

内部文書やデータセットを使用して、分析に関する質問に答える対話型インターフェースを提供する。

- * 機密性の高い医療関連データが、Fabrikam Inc.のAzureテナント外に公開されないようにしてください。
- * 再現性と監査可能性を備えたモデルのトレーニングおよびデプロイプロセスを可能にする。
- * プロンプト戦略と微調整されたモデルを比較するための実験を支援する。
- * モデルをランク付けされた嗜好に合わせて調整し、長期的な行動を最適化する。

導入期間中、既存の分析ワークロードへの影響を最小限に抑える。

技術要件

事業目標を支援するため、Fabrikam Inc.は以下の技術要件を特定しました。

- * Azure Machine Learningワークスペースを使用して、データ資産、モデル、および環境を一元的に管理します。
- * すべてのトレーニングジョブに対して、実験追跡とモデルのバージョン管理を実装する。

手動でノートブックを実行するのではなく、パイプラインを使用してトレーニングと評価をオーケストレーションします。

- * 段階的なロールアウトとロールバックをサポートする、従来型の機械学習モデルをデプロイします。
- * RAGベースのソリューション出力品質を向上させる。
- * 入出力ペアを含む実データに基づいた既存の評価データセットを使用する。

* 迅速なエンジニアリングでは不十分な場合にのみ、高度な微調整技術を適用します。課題と制約 Fabrikam Inc. は、ネットワーク アクセスを制限し、長期間秘密を保持することを避けることを要求する社内セキュリティ ポリシーを遵守する必要があります。データ サイエンス チームは Azure DevOps の経験が限られているため、ソリューションはカスタム インフラストラクチャよりもマネージド サービスと自動化を優先する必要があります。

コスト予測可能性は重要です。経営陣は可能な限りサーバーレスまたはマネージドコンピューティングオプションを好みますが、安定した本番ワークロードに対しては専用コンピューティングも承認する用意があります。

問題提起

Fabrikam Inc.は、生成型AIモデルの信頼性の高いトレーニング、評価、デプロイ、および反復を可能にするAzureベースのAI運用ソリューションを設計および実装する必要があります。このソリューションは、ガバナンス、セキュリティ、および運用上の安定性を確保しながら、実験と段階的な展開をサポートする必要があります。データサイエンスチームとプラットフォームチームは、Azure Machine LearningとMicrosoft Foundryの機能を活用して、このソリューションを実現するために協力する必要があります。

実験結果の一貫性を確保できるような実験追跡戦略を提案する必要があります。どのような戦略を提案すべきでしょうか？

A. Azure Machine Learning ジョブの出力ログ

B. MLflow実験追跡

C. Application Insights ログ

D. Azure Monitor アラート

正解: ([正解を表示します](#))

シナリオ :

データサイエンスチームが現在直面している課題は次のとおりです。実験追跡が一貫していない。ビジネス目標をサポートするために、Fabrikam Inc. は次の技術要件を特定しました。すべてのトレーニングジョブに対して実験追跡とモデルバージョン管理を実装する。

AzureベースのAI運用において、MLflowをAzure Machine Learning (Azure ML)と統合することで、実験の追跡、モデルのバージョン管理、および従来の機械学習ワークロードと生成型AIワークロードの両方のライフサイクル管理を行うための統一されたインターフェースが提供されます。

直接的な実施戦略

実験結果の一貫性を確保し、迅速な戦略と微調整されたモデルを比較するために、以下のアーキテクチャアプローチを使用してください。

一元的な追跡 :MLflowの追跡URIをAzure MLワークスペースを指すように構成します。

これにより、ローカルノートブック、リモートトレーニングジョブ、またはプロンプトフローからのすべてのログを、単一の「実験」ダッシュボードに集約できます。

プロンプト戦略の比較 :Azure ML Prompt Flow を使用して、プロンプトのバリエーションを開発およびテストします。

Prompt Flow は、Azure ML Studio で微調整されたモデル メトリックと併せて表示できるメトリック (現実性や関連性など) を自動的にログに記録します。

モデルのバージョン管理 :Azure ML 内でホストされている MLflow モデルレジストリを使用します。トレーニングまたはファインチューニングが成功するたびに、名前付きモデルの新しいバージョンとして登録し、データからデプロイメントまでの明確な履歴管理を実現します。

参照 :

<https://learn.microsoft.com/en-us/azure/machine-learning/how-to-use-mlflow-cli-runs>

質問: 23

ホットスポットに関する質問

Azure Machine Learningでモデルをトレーニングします。

後で比較するために、実験の詳細を記録する予定です。トレーニングコードは、各実行におけるパラメータと指標をログに記録する必要があります。

以下のトレーニングスクリプトを確認してください。

```
1 import mlflow
2 import mlflow.sklearn
3 from sklearn.linear_model import LogisticRegression
4 from sklearn.datasets import load_iris
5
6 X, y = load_iris(return_X_y=True)
7
8 mlflow.set_experiment("classification-experiment")
9
10 with mlflow.start_run():
11     model = LogisticRegression(max_iter=200)
12     model.fit(X, y)
13
14     mlflow.log_param("max_iter", 200)
15     y_pred = model.predict(X)
16     accuracy = accuracy_score(y, y_pred)
17     mlflow.log_metric("accuracy", accuracy)
18
19     mlflow.sklearn.log_model(model, "model")
```

トレーニングスクリプトが実験追跡要件を満たしているかどうかを確認する必要があります。以下の各項目について、該当する場合は「はい」を選択してください。該当しない場合は「いいえ」を選択してください。

注：正解ごとに1ポイントが加算されます。

MLflow experiment tracking

Statement	Yes	No
The code ensures that training parameters and metrics are tracked for each run.	<input type="checkbox"/>	<input type="checkbox"/>
The code uses the experiment name to define the artifact path of the logged model.	<input type="checkbox"/>	<input type="checkbox"/>
The code associates the run with a named experiment.	<input type="checkbox"/>	<input type="checkbox"/>

正解:

MLflow experiment tracking



Statement	Yes	No
The code ensures that training parameters and metrics are tracked for each run.	<input checked="" type="checkbox"/>	<input type="checkbox"/>
The code uses the experiment name to define the artifact path of the logged model.	<input checked="" type="checkbox"/>	<input type="checkbox"/>
The code associates the run with a named experiment.	<input checked="" type="checkbox"/>	<input type="checkbox"/>

質問: 24

あなたは、Azure AI Searchを使用してインデックス付きナレッジベースからドキュメントを取得する、検索拡張生成 (RAG) システムを管理しています。

システムは以下の検索要件をサポートする必要があります。

正確なポリシー識別子を含むクエリは、意味的な類似性が低い場合でも、一致するドキュメントを返さなければなりません。

自然言語による質問では、キーワードが完全に一致しない場合でも、意味的に関連性の高い文書を優先的に扱う必要がある。

要件を満たすように、データ取得方法を設定する必要があります。

各要件に対して、取得動作をどのように設定すべきでしょうか？回答するには、回答欄で適切なオプションを選択してください。注：正解ごとに1ポイントが加算されます。

Retrieval requirement

Exact identifier matching

Configuration

- Semantic ranking only
- Keyword-based retrieval disabled
- Vector similarity without keyword scoring
- Keyword-based retrieval with lexical scoring

Natural-language relevance

- Exact-match filtering only
- Keyword-only search without embeddings
- Keyword-based retrieval with lexical scoring
- Semantic ranking over vector search results

正解:

Retrieval requirement

Exact identifier matching

Configuration

- Semantic ranking only
- Keyword-based retrieval disabled
- Vector similarity without keyword scoring
- Keyword-based retrieval with lexical scoring

Natural-language relevance

- Exact-match filtering only
- Keyword-only search without embeddings
- Keyword-based retrieval with lexical scoring
- Semantic ranking over vector search results

Explanation:

クエリの種類によって、根本的に異なる検索アルゴリズムが必要になります。正確なポリシー識別子を含むクエリの場合、キーワード検索または BM25 検索が適切な選択肢です。BM25 は用語頻度と逆文書頻度に基づいて文書をスコアリングするため、POL などの特定のポリシー識別子に完全に一致すると、2024-HR-042 は、意味的な文脈に関係なく非常に高いスコアを獲得しています。これは、意味的な類似性は低いものの、用語の完全一致が重要な場合に最適なアプローチです。キーワードが完全に一致しない可能性のある自然言語の質問の場合、セマンティック検索またはベクトル検索が適切な選択肢となります。これは、ベクトル埋め込みが正確な

トークンではなく意味を捉えるため、ユーザーの語彙がドキュメントの用語と異なっても、関連するドキュメントを見つけることができます。Azure AI Search は、ハイブリッド検索機能を通じて両方のモードをサポートしており、適切な構成では、各クエリタイプを最適な検索アルゴリズムにマッピングします。

Microsoft Learn リファレンス トピック: Azure AI Search でハイブリッド検索を構成する - BM25 キーワード検索と

意味ベクトル検索



質問: 25

トレーニング中、上流のデータ変更によってスキーマの不一致が発生し、パイプラインが失敗することがあります。無効なデータがトレーニングステップに到達しないようにする、堅牢で自動化されたソリューションが必要です。最適なアプローチは何でしょうか？

- A. 故障が発生した場合は手動で再トレーニングしてください。
- B. スキーマの違いを無視する
- C. パイプラインにデータ検証コンポーネントを追加する
- D. より大きなコンピューティングを使用する

正解: ([正解を表示します](#))

質問: 26

GPU対応クラスタでモデルをトレーニングし、CPUベースのエンドポイントにデプロイしています。最近、依存関係の不一致が原因で推論エラーが発生しています。一貫性を確保するにはどうすればよいでしょうか？

- A. トレーニングと推論に同じ計算能力を使用する
- B. 環境設定の定義と再利用
- C. エンドポイントの計算サイズを増やす
- D. バッチエンドポイントを使用する

正解: ([正解を表示します](#))

環境設定を定義して再利用することで、トレーニングと推論の間で依存関係の一貫性が保たれます。これにより、ライブラリの不一致によって引き起こされる実行時エラーを防ぐことができます。

同一の計算リソースを使用することは不要であり非効率的です。なぜなら、一貫性はハードウェアではなく環境構成に依存するからです。

質問: 27

あるチームは、共有プロンプトテンプレートを利用する複数のAIアプリケーションをMicrosoft Foundry上で開発している。

チームは、プロジェクト間でプロンプトコンテンツを追跡、バージョン管理、再利用するための集中管理された方法を必要としている。

プロンプトコンテンツを追跡し、再利用するためのソリューションを提案する必要があります。

どちらのアプローチを推奨すべきでしょうか？

- A. プロンプトをバージョン管理されたファイルとしてGitリポジトリに保存します。
- B. Azure Machine Learningワークスペースでプロンプトをデータセットとして登録します。
- C. アプリケーション設定ファイルにプロンプトを直接埋め込む。
- D. フォルダーレベルの整理でプロンプトを Azure Blob Storage に永続化します。

正解: ([正解を表示します](#))

Microsoft Foundryでは、複数のAIアプリケーション間で一貫性、バージョン管理、および再利用性を確保するために、プロンプトテンプレートをGitリポジトリ (GitHubなど)に一元管理することが、推奨されるGenAIOpsの実践方法となっています。

プロンプトをバージョン管理されたファイルとしてGitリポジトリに保存することは、Microsoft Foundryアプリケーションにとって優れたアプローチです。プロンプトをコード (PromptOps)のように扱うことで、明確な監査証跡、プルリクエストによるピアレビュー、そして容易なロールバックが可能になります。

この集中型システムを効果的に運用するには、以下の3つの要素を考慮する必要があります。

集中型リポジトリ :テンプレートをJSONやYAMLなどの構造化された形式で保存する単一の「プロンプトバンク」リポジトリを使用します。モデルバージョン、温度、入力変数などのメタデータを含めます。

プロンプトレジストリ/SDK: アプリケーションがAPIまたはGitサブモジュールを介してプロンプトの「最新」バージョンまたは「タグ付けされた」バージョンを取得できるようにする、小規模な内部ユーティリティを開発します (またはAzure AI StudioのPrompt Flowなどのツールを使用します)。

CI/CD統合 :プロンプトファイルが更新された際に「プロンプト評価」パイプラインがトリガーされるようにテストを自動化し、変更によって依存プロジェクト全体のAIパフォーマンスが低下しないことを保証します。

参照 :

<https://www.getmaxim.ai/articles/best-practices-for-prompt-management-in-ai-applications>

質問: 28

Azure Machine Learning を使用すると、同じワークスペースを使用して複数の実験にわたってモデルをトレーニングできます。

異なるジョブの結果を比較するためには、トレーニングの実施状況を一元的に記録する必要があります。

トレーニング中は、パフォーマンス値を記録して、実験実行履歴に表示させる必要があります。

実験追跡を設定する必要があります。

各要件に対してどのような設定を行うべきですか？回答するには、回答欄で適切なオプションを選択してください。

注 : 正解ごとに1ポイントが加算されます。

Configure experiment tracking

Requirement

Ensure runs are recorded in the workspace experiment history.



Microsoft

Record performance values during model training.

Configuration

▼

- Data asset
- MLflow tracking URI
- Azure Monitor workspace

▼


- Prompt flow
- Model registry
- MLflow metrics logging

正解:

Configure experiment tracking

Requirement

Ensure runs are recorded in the workspace experiment history.



Microsoft

Record performance values during model training.

Configuration

▼

- Data asset
- MLflow tracking URI
- Azure Monitor workspace

▼

- Prompt flow
- Model registry
- MLflow metrics logging

Explanation:

Azure Machine Learning の実験追跡は、2 つの相補的な概念に基づいて構築されています。まず、実験は関連する実行をグループ化する名前付きコンテナです。トレーニングコードの開始時に実験名を指定して `mlflow.set_experiment` を呼び出すと、以降のすべての実行が AML ワークスペースでその実験名の下にグループ化され、必要な一元化されたレコードが作成されます。次に、メトリックは、精度、損失、AUC などのスカラー値で、モデルのパフォーマンスを表します。トレーニング中にメトリック名と値を指定して `mlflow.log_metric` を呼び出すと、これらの値が実験履歴の実行レコードに保持されます。これらの値は Azure ML Studio の実行詳細ページに表示され、実験比較ビューを使用して実行間で比較できます。`set_experiment` を指定しない場合、実行は既定の実験に分類されます。`log_metric` を指定しない場合、実行履歴には表示または比較するパフォーマンス データがありません。

Microsoft Learn リファレンス トピック: Azure Machine Learning の MLflow を使用して機械学習実験を追跡する

Configure experiment tracking

Requirement

Ensure runs are recorded in the workspace experiment history.

Record performance values during model training.

Configuration

The screenshot shows a configuration window with two main sections. The first section, titled 'Data asset', contains three fields: 'MLflow tracking URI' (highlighted with a red border), 'Azure Monitor workspace', and a dropdown menu. The second section, titled 'Model registry', contains a 'Microsoft' logo, the text 'Prompt flow Model registry', and a checkbox for 'MLflow metrics logging' (highlighted with a red border).

質問: 29

ホットスポットに関する質問

Python SDK v2 を使用して、workspace1 という名前の Azure Machine Learning ワークスペースを管理します。mlstorage1 という名前の汎用 v2 Azure ストレージ アカウントを作成します。このストレージ アカウントには、mlcontainer1 という名前のパブリック アクセス可能なコンテナが含まれています。このコンテナには、CSV 形式のファイルを含む 10 個の BLOB が格納されています。

mlcontainer1 という名前のコンテナ内のすべてのプロブを参照するデータアセットを作成するには、Python SDK v2 コードを開発する必要があります。

Python SDK v2 のコードを完成させる必要があります。

コードをどのように完成させればよいでしょうか？ 回答するには、回答欄で適切な選択肢を選んでください。

注：正解ごとに1ポイントが加算されます。

Answer Area



```
sample_dataset = Data(  
  path=   


|         |
|---------|
| wasbs   |
| abfss   |
| azureml |

  
  type=AssetTypes.  


|             |
|-------------|
| URI_FILE    |
| URI_FOLDER  |
| URI_MLTABLE |

  
  description="sample_dataset",  
  name="sample_dataset",  
  version='1.0'  
)
```

正解:

```

Answer Area
sample_dataset = Data(
  path=
  type=AssetTypes.
  description="sample_dataset",
  name="sample_dataset",
  version='1.0'
)

```

質問: 30

ドラッグアンドドロップ問題

ある組織は、Microsoft Foundryを使用して、ストレージアカウントやベクターデータベースなどの共有Azureリソースにアクセスする生成型AIプロジェクトを開発しています。組織のセキュリティポリシーでは、秘密鍵に基づく認証を廃止し、最小権限のアクセスを徹底することが求められている。

IDとアクセスを以下のように構成する必要があります。

サービスは、保存された認証情報を使用せずに認証を行います。

権限はプロジェクト全体および共有リソース全体にわたって適切に設定されています。

それぞれの要件に応じて、適切なIDまたはアクセスメカニズムを設定する必要があります。

各要件を満たすために、Microsoft Foundry でどのような設定を行う必要がありますか？回答するには、適切な設定メカニズムを該当する要件に移動してください。各設定メカニズムは、1回、複数回、またはまったく使用しない場合があります。コンテンツを表示するには、ペイン間の分割バーを移動したり、スクロールしたりする必要がある場合があります。

注：正解ごとに1ポイントが加算されます。

Configuration mechanisms	Requirement	Configuration mechanism
API key	Allow Microsoft Foundry workloads to access Azure resources with key-less authentication.	
Managed identity	Control which users can manage projects and deployments.	
Role-based access control (RBAC) role assignment		
Service principal		

正解:

Configuration mechanisms	Requirement	Configuration mechanism
API key	Allow Microsoft Foundry workloads to access Azure resources with key-less authentication.	Managed identity
Managed identity	Control which users can manage projects and deployments.	Role-based access control (RBAC) role assignment
Role-based access control (RBAC) role assignment		
Service principal		

質問: 31

チームは分類モデルを本番環境に展開し、パフォーマンスとデータの変化を監視する。

チームは、予測精度が大幅に低下した場合に、以下の処理が自動的に実行されるようにしたいと考えています。

関係者には、価格下落について通知しなければならない。

閾値を超えた場合は、再訓練を開始する必要がある。

要件を満たすように監視システムを設定する必要があります。

どの4つの行動を順番に実行すべきでしょうか？回答するには、行動リストから適切な行動を回答欄に移動させ、正しい順序に並べ替えてください。

Configure monitoring	Answer Area
Enable scheduled or event-based retraining.	
Manually inspect prediction logs after failures.	
Define performance thresholds for monitored metrics.	
Configure alerts to notify stakeholders.	
Monitor baseline metrics from production traffic.	

正解:

Configure monitoring

Answer Area

Enable scheduled or event-based retraining.	Define performance thresholds for monitored metrics.
Manually inspect prediction logs after failures.	Configure alerts to notify stakeholders.
Define performance thresholds for monitored metrics.	Monitor baseline metrics from production traffic.
Configure alerts to notify stakeholders.	Enable scheduled or event-based retraining.
Monitor baseline metrics from production traffic.	

Explanation:

Microsoft の運用モデル監視に関するガイダンスでは、4つの段階からなる手順が規定されています。まず、デプロイされたエンドポイントで Azure ML モデルモニターを構成し、追跡するメトリックとスケジュールを指定します。

次に、モデルのパフォーマンスが許容できないとみなされるしきい値を定義します。これがトリガー条件となります。3番目に、監視対象のメトリックをしきい値と比較して、しきい値を超えた場合にトリガーされる Azure Monitor アラートルールを作成します。このアラートルールは、電子メール、SMS、または Teams Webhook を介して関係者に通知を送信するアクショングループに関連付けられます。4番目に、アクショングループには、Azure Machine Learning パイプラインの公開された REST エンドポイントを指す Webhook アクションが含まれており、これにより再トレーニングジョブが自動的に開始されます。この一連の処理により、検出、通知、および修復が明確に分離され、Microsoft が推奨する MLOps 自動化パターンに合致しています。

Microsoft Learn リファレンス トピック: 監視アラートに基づいてモデルの再トレーニングを自動化する - Azure Machine Learning MLOps

Configure monitoring	Answer Area
Enable scheduled or event-based retraining.	Define performance thresholds for monitored metrics.
Manually inspect prediction logs after failures.	Configure alerts to notify stakeholders.
Define performance thresholds for monitored metrics.	Monitor baseline metrics from production traffic.
Configure alerts to notify stakeholders.	Enable scheduled or event-based retraining.
Monitor baseline metrics from production traffic.	

有効的なAI-300問題集はJPNTTest.com提供され、AI-300試験に合格することに役に立ちます！JPNTTest.comは今最新AI-300試験問題集を提供します。JPNTTest.com AI-300試験問題集はもう更新されました。ここでAI-300問題集のテストエンジンを手に入れます。最新版のアクセス、<https://www.jpntest.com/shiken/AI-300-mondaishu> 126問、30%ディスカウント、特別な割引コード: **JPNshiken**」

リアルタイムエンドポイントで、断続的なレイテンシの急増が発生しています。調査の結果、インスタンスが非アクティブ時にゼロまでスケールダウンしていることが判明しました。コストを大幅に増加させることなく、レイテンシを削減する必要があります。

何を設定すればよいですか？

- A. タイムアウト設定を増やす
- B. 最小インスタンス数を設定する
- C. バッチエンドポイントに切り替える
- D. ログ記録を減らす

正解: B (コメントを发表する)

コールドスタートとは、インスタンスがゼロまでスケールダウンし、新しいリクエストを処理するために再起動が必要になる現象です。

最小インスタンス数を設定することで、常に少なくとも1つのインスタンスが実行されていることが保証され、レイテンシーの急増が軽減されます。タイムアウト時間を長くしても、コールドスタート遅延の根本原因は解決されません。

質問: 33

ドラッグアンドドロップ問題

チームは、複数のAzure Machine Learningパイプラインを使用してトレーニングジョブを実行します。

チームは、すべての実行において同じPythonパッケージとシステムライブラリが使用されることを保証しなければなりません。ソリューションは、トレーニングコードを変更することなく、依存関係の更新をバージョン管理できるものでなければなりません。

実行時の依存関係が一貫性があり、再利用可能になるようにワークスペースを設定する必要があります。

どの4つの行動を順番に実行すべきでしょうか？回答するには、行動リストから適切な行動を回答欄に移動させ、正しい順序に並べ替えてください。

Configure Azure Machine Learning pipelines

- Reference the environment in training jobs and pipelines.
- Register the environment in the Azure Machine Learning workspace.
- Store dependency versions in a configuration file.
- Modify training scripts to install required packages at runtime.
- Define the required dependencies in an environment specification.
- Create a new version of the environment when dependencies change.


Answer Area

Microsoft

jpnsshiken.com

正解:

Configure Azure Machine Learning pipelines	Answer Area
Reference the environment in training jobs and pipelines.	Define the required dependencies in an environment specification.
Register the environment in the Azure Machine Learning workspace.	Register the environment in the Azure Machine Learning workspace.
Store dependency versions in a configuration file.	Create a new version of the environment when dependencies change.
Modify training scripts to install required packages at runtime.	Reference the environment in training jobs and pipelines.
Define the required dependencies in an environment specification.	
Create a new version of the environment when dependencies change.	



質問: 34

チームがAzure Machine Learningのリアルタイムエンドポイントにモデルをデプロイします。その後、エンドポイントにいくつかの更新をデプロイします。

新しいデプロイメントがリリースされた後、エンドポイントはエラーを返します。

できるだけ早くサービスを復旧させる必要があります。

まず最初に何をすべきでしょうか？

- A. トラフィックを以前のデプロイメントに戻します。
- B. エンドポイントを削除し、すぐに再デプロイします。
- C. 認証タイプをAzure Machine Learningトークンベース認証に変更します。
- D. 計算サイズを増やします。

正解: ([正解を表示します](#))

復旧速度が最も重要な要件です。トラフィックを以前のデプロイメントにロールバックするのが最も迅速な方法です。以前のデプロイメントは同じエンドポイントにまだ存在するため、単一の Azure ML CLI コマンドまたは SDK 呼び出しを使用してトラフィックの重みを更新するだけで済みます。古いデプロイメントを 100%、新しいデプロイメントを 0% に設定すれば、コンピューティングリソースを再プロビジョニングすることなく数秒で完了します。削除して再デプロイする (オプション B) には、エンドポイントの削除、プロビジョニング解除の待機、エンドポイントの再作成、モデルの再デプロイ、コンテナの起動の待機が必要で、10 分から 30 分かかる場合があります。認証タイプの変更 (オプション C) は、不良モデルによって発生するアプリケーション エラーには影響しません。コンピューティング サイズの増加 (オプション D) は、モデルのロジック エラーを修正しません。Azure ML がトラフィック分割による複数の同時デプロイメントをサポートしているのは、まさにこの即時ロールバック パターンを実現するためです。

Microsoft Learn リファレンス トピック: マネージド オンライン エンドポイントでのデプロイのロールバック - Azure Machine Learning の安全なデプロイ方法

質問: 35

注 :この問題は、同じシナリオを提示する一連の問題の一部です。このシリーズの各問題には、提示された目標を満たす可能性のある独自の解答が含まれています。問題セットによっては、複数の正解がある場合もあれば、正解がない場合もあります。

このセクションの質問に回答すると、後から戻って回答することはできません。そのため、これらの質問は復習画面には表示されません。

Microsoft Foundryでは、プロンプトフローに沿って作業を進めます。

プロンプトは手動で評価し、プロンプトのバリエーション間で結果を比較する必要があります。

評価のためには、各フロー実行における入力、出力、トークン使用量、および遅延時間を記録する必要があります。

解決策 :プロンプトのバリエーションを作成し、評価エクスペリエンスでそれらの出力を比較します。

その解決策は目標を達成しているか？

- A. はい

B. いいえ

正解: ([正解を表示します](#))

Microsoft Foundry のプロンプト フロー エディターにおける評価機能では、プロンプトのバリエーション全体にわたる総合的な品質スコアが表示されます。どのバリエーションがより一貫性のある回答を生成するか、どのバリエーションが根拠の深さにおいてより高いスコアを獲得するかが分かります。

ただし、実行ごとの生のテレメトリ（呼び出しごとのトークン数、リクエストごとの遅延時間（ミリ秒単位）、各実行の正確な入出力ペアなど）は公開されません。評価エクスペリエンスは、詳細な運用テレメトリではなく、比較品質スコアリングを目的として設計されています。入力、出力、トークンの使用状況、および遅延を詳細な実行レベルで取得するには、Microsoft Foundry でトレースを有効にする必要があります。トレースは、各 LLM 呼び出しを、タイミング、トークン消費量、および完全な入出力ペイロードを含む構造化されたスパンとして記録します。これは、評価スコアとは根本的に異なるビューであり、4 つの取得要件すべてを直接満たします。

Microsoft Learn リファレンス トピック: Microsoft Foundry でのトレースとデバッグのプロンプト フロー - トレースとデバッグ。

評価

質問: 36

注 :この問題は、同じシナリオを提示する一連の問題の一部です。このシリーズの各問題には、提示された目標を満たす可能性のある独自の解答が含まれています。問題セットによっては、複数の正解がある場合もあれば、正解がない場合もあります。

このセクションの質問に回答すると、後から戻って回答することはできません。そのため、これらの質問は復習画面には表示されません。

Microsoft Foundryでは、プロンプトフローに沿って作業を進めます。

プロンプトは手動で評価し、プロンプトのバリエーション間で結果を比較する必要があります。

評価のためには、各フロー実行における入力、出力、トークン使用量、および遅延時間を記録する必要があります。

解決策 :Microsoft Foundryで、プロジェクトのプロンプトフローのトレースを有効にし、テスト実行を実行してトレースデータを生成します。

その解決策は目標を達成しているか？

A. はい

B. いいえ

正解: ([正解を表示します](#))

正しい :

* Microsoft Foundry で、プロジェクトのプロンプト フローのトレースを有効にし、テスト ランを実行してトレース データを生成します。

正しくない :

* 評価エクスペリエンスでプロンプトのバリエーションを作成し、その出力を比較します。

* 実行前にプロンプトフローSDKを使用してフローのトレースを有効にします。その後、フローを実行してトレース可能な結果を生成します。

注記 :

Azure AI Foundry では、トレースを有効にして一括テスト機能を使用することで、これらのメトリックを取得して比較できます。これにより、共通のデータセットに対して、さまざまなプロンプトのバリエーションを体系的に評価できます。

プロンプトのバリエーションを評価および比較する手順

*-> 1. トレースを有効にする

Prompt Flowプロジェクトに移動してください。

フロー作成ページの上にある「トレース」トグルを探してください。

オンに切り替えてください。

これにより、すべての実行において、レイテンシ、トークン数、およびノードレベルの入出力が確実に記録されます。

2. プロンプトのバリエーションを作成する

フロー内で、テストしたいLLMノードを特定します。

「バリエーション」をクリックすると、プロンプトの複数のバージョンを作成できます（例Variant_0、Variant_1）。

これにより、異なる指示や少数のサンプルを並べてテストすることができます。

3. 一括テスト（評価を実行する）

4. 結果を分析する

参照：

<https://www.linkedin.com/pulse/streamlining-generative-ai-development-azure-foundry-tracing-taneja-mbwze>

質問: 37

モデルを本番環境にデプロイしたものの、予測精度を評価するためのラベル付きデータがありません。しかし、モデルの状態を継続的に監視する必要があります。最適な戦略は何でしょうか？

- A. モニター精度指標
- B. データドリフト検出を使用する
- C. 監視を無効にする
- D. 手動評価のみを実施する

正解: [\(正解を表示します\)](#)

ラベル付きデータが利用できない場合、従来の精度指標は計算できません。データドリフト検出は、入力データの分布の変化を監視し、潜在的なパフォーマンス低下の指標として機能します。これにより、ラベル付きデータが利用可能になる前に問題を早期に検出できます。

質問: 38

ある組織は、開発用と本番用にそれぞれ別のAzure Machine Learningワークスペースを維持している。

両方の環境では、重複することなく、同じ検証済みアセットを使用する必要があります。

アセットはワークスペース間で共有される必要があるが、同時に一元的なガバナンスとバージョン管理を維持しなければならない。

アセットをコピーせずに、ワークスペース間で再利用できるようにする必要があります。

あなたはどうすべきでしょうか？

- A. ワークスペースレベルのGit統合を有効にし、リポジトリ間でアセットを同期します。
- B. アセットをパイプラインコンポーネントとして公開します。
- C. アセットを含む共有 Azure Machine Learning 環境を作成します。
- D. アセットを Azure Machine Learning レジストリに公開します。

正解: [D \(コメントを发表する\)](#)

Microsoft の Azure Machine Learning のドキュメントでは、レジストリは個々のワークスペースの上位に位置する組織レベルのリポジトリであると説明されています。モデル、環境、コンポーネントなどのアセットを Azure ML レジストリに公開すると、物理的な重複なしに、同じ Azure テナント内の任意のサブスクリプションの任意のワークスペースからアクセスできるようになります。レジストリは、完全なバージョン履歴を持つ単一の情報源を維持します。オプション A (Git 統合) は、コンパイルされた ML アーティファクトではなく、コードを同期します。オプション B (パイプライン コンポーネント) は、再利用可能なパイプライン ステップをパッケージ化しますが、ワークスペース間の共有は解決しません。オプション C (共有環境) は、ランタイムの依存関係に対応しますが、ML アセットの全範囲には対応しません。レジストリは、集中管理、バージョン管理、ワークスペース間のアセット共有のために特別に構築されたソリューションであり、成熟した MLOps 組織に Microsoft が推奨するパターンです。

Microsoft Learn リファレンス トピック: Azure Machine Learning レジストリを使用してワークスペース間でアセットを共有する

質問: 39

注 :この問題は、同じシナリオを提示する一連の問題の一部です。このシリーズの各問題には、提示された目標を満たす可能性のある独自の解答が含まれています。問題セットによっては、複数の正解がある場合もあれば、正解がない場合もあります。

このセクションの質問に回答すると、後から戻って回答することはできません。そのため、これらの質問は復習画面には表示されません。
Azure Machine Learning ワークスペースを管理しています。script.py という名前の Python スクリプトは、training_data という名前の引数を読み取ります。
training_data 引数は、dataset 1.csv という名前のファイル内のトレーニングデータへのパスを指定します。

あなたは、script.py という Python スクリプトを、機械学習モデルをトレーニングするコマンドジョブとして実行する予定です。
スクリプトをトレーニングジョブとして送信する際には、データセットのパスをパラメータ値として渡すコマンドを指定する必要があります。

解決策 `python script.py --trainingdata ${{inputs.training_data}}`

その解決策は目標を達成しているか？

A. はい

B. いいえ

正解: ([正解を表示します](#))

Microsoft の Azure Machine Learning SDK v2 コマンド ジョブに関するドキュメントによると、コマンド文字列の入力引数は、Python スクリプトの argparse 構成で定義されている引数名と完全に一致する必要があります。スクリプトは、アンダースコア付きの training_data という名前の引数を読み取りますが、提案されているコマンドはアンダースコアなしの --trainingdata を渡します。Python の argparse はこれらをまったく異なる引数名として扱うため、スクリプトは --training_data 引数に対して None を受け取り、実行時エラーが発生します。コマンド文字列で入力を参照するためのプレースホルダー構文は正しいため、このソリューションの利点となります。しかし、引数名の不一致だけでも、このソリューションが失敗する原因となります。修正されたコマンドでは、スクリプトで定義されている引数名と完全に一致する --training_data を使用します。

Microsoft Learn リファレンス トピック: コマンド ジョブの入力と出力の構成 - Azure Machine Learning SDK v2 リファレンス

質問: 40

ホットスポットに関する質問

Azure Machine Learning を使用すると、同じワークスペースを使用して複数の実験にわたってモデルをトレーニングできます。
異なるジョブの結果を比較するためには、トレーニングの実施状況を一元的に記録する必要があります。

トレーニング中は、パフォーマンス値を記録して、実験実行履歴に表示させる必要があります。

実験追跡を設定する必要があります。

各要件に対して、どのような設定を行うべきですか？回答するには、回答欄で適切なオプションを選択してください。

注：正解ごとに1ポイントが加算されます。

Configure experiment tracking

Requirement

Ensure runs are recorded in the workspace experiment history.

Record performance values during model training.

Configuration

Data asset
MLflow tracking URI
Azure Monitor workspace

Prompt flow
Model registry
MLflow metrics logging

正解:

Configure experiment tracking

Requirement

Ensure runs are recorded in the workspace experiment history.

Record performance values during model training.

Configuration

Data asset
MLflow tracking URI
Azure Monitor workspace

Prompt flow
Model registry
MLflow metrics logging

質問: 41

ホットスポットに関する質問

あなたは、Microsoft Foundry で行われる高度なファインチューニング作業に使用されるデータセットを確認しています。

微調整処理では、選好比較データを使用します。

以下のデータセットの抜粋を確認してください。

Training record 1:

```
01 {"input":[{"role":"system","content":"You are a policy assistant."},
02       {"role":"user","content":"Summarize Policy X for managers."}],
03  "preferred_output":[{"role":"assistant","content":"Policy X applies to all managers and outlines approval
requirements."}],
04  "non_preferred_output":[{"role":"assistant","content":"Policy X applies to all managers and outlines approval
requirements."}]}
```

Training record 2:

```
01
02 {"input":[{"role":"system","content":"You are a policy assistant."},
03       {"role":"user","content":"What is the retention period?"}],
04  "preferred_output":[{"role":"assistant","content":"The retention period is seven years."}],
05  "non_preferred_output":[{"role":"assistant","content":"The retention period is five years."}]}
```

以下の各記述について、正しい場合は「はい」を選択してください。そうでない場合は「いいえ」を選択してください。

注：正解ごとに1ポイントが加算されます。

Statement	Yes	No
The first record provides a usable preference signal for preference-based fine-tuning.	<input type="radio"/>	<input type="radio"/>
The second record provides a usable preference signal for preference-based fine-tuning.	<input type="radio"/>	<input type="radio"/>
Each preferred and non-preferred output in the dataset contains a valid assistant message as required for direct preference optimization.	<input type="radio"/>	<input type="radio"/>
Both records must contain different preferred and non-preferred outputs to produce usable training signals.	<input type="radio"/>	<input type="radio"/>

正解:

Statement	Yes	No
The first record provides a usable preference signal for preference-based fine-tuning.	<input type="radio"/>	<input checked="" type="radio"/>
The second record provides a usable preference signal for preference-based fine-tuning.	<input checked="" type="radio"/>	<input type="radio"/>
Each preferred and non-preferred output in the dataset contains a valid assistant message as required for direct preference optimization.	<input type="radio"/>	<input checked="" type="radio"/>
Both records must contain different preferred and non-preferred outputs to produce usable training signals.	<input checked="" type="radio"/>	<input type="radio"/>

質問: 42

Azure OpenAI Service ベースモデルのデプロイメントが完了しています。

あなたはモデルを微調整する予定です。

トレーニングデータを含むファイルを準備する必要があります。

どのファイル形式を使用すべきですか？

- A. CSV
- B. TSV
- C. JSONL
- D. JSON

正解: **C** ([コメントを发表する](#))

Azure OpenAI Service のファインチューニングには、JSON Lines (JSONL) 形式のトレーニングデータが必要です。JSONL は、各行が自己完結型の有効な JSON オブジェクトで、1つのトレーニング例を表すテキストファイルです。チャットのファインチューニングの場合、各行にはシステム、ユーザー、アシスタントのターンを含むメッセージ配列が含まれます。JSONL は、ストリーミング可能で、プログラムによる生成が容易であり、Azure OpenAI ファインチューニング API で直接サポートされているため、機械学習データセットに最適です。CSV (オプション A) と TSV (オプション B) は表形式であり、チャットモデルに必要なネストされた複数ターンの会話構造をネイティブに表現することはできません。プレーン JSON (オプション D) では、ファイル全体を単一のオブジェクトとして読み込む必要がありますが、これは大規模なデータセットには非現実的であり、Azure OpenAI ファインチューニング エンドポイントでは受け入れられません。Azure OpenAI のトレーニング ファイルには、必ず UTF-8 エンコーディングの JSONL を使用してください。

Microsoft Learn リファレンス トピック: Azure OpenAI のファインチューニング用のトレーニング データの準備 - JSONL ファイル形式

質問: 43

チームが Azure Machine Learning のリアルタイムエンドポイントにモデルをデプロイします。その後、エンドポイントにいくつかの更新をデプロイします。

新しいデプロイメントがリリースされた後、エンドポイントはエラーを返します。

できるだけ早くサービスを復旧させる必要があります。

まず最初に何をすべきでしょうか？

- A. トラフィックを以前のデプロイメントに戻します。
- B. エンドポイントを削除し、すぐに再デプロイします。
- C. 認証タイプを Azure Machine Learning トークンベース認証に変更します。

D. 計算サイズを増やします。

正解: ([正解を表示します](#))

サービスをできるだけ早く復旧するには、Azure Machine Learning オンライン エンドポイントのトラフィック割り当て設定を更新して、トラフィックを以前のデプロイメントに戻すことができます。

Azure Machine Learning のマネージド オンライン エンドポイントは、単一のエンドポイントの下で複数のデプロイメントをサポートしており、バージョン間でトラフィックを瞬時に切り替えることができるブルー/グリーン デプロイメント戦略を実現します。

このアプローチの主な利点

即時復旧 : トラフィックの切り替えはルーティングの変更であり、以前のモデルのコードや環境を再デプロイする必要がないため、最も迅速な復旧方法となります。

ダウンタイムなし : 以前のデプロイメントは「ウォーム」(アクティブだがトラフィックを受信していない状態)のままなので、切り替えはサービスを中断することなく行われます。

デバッグのための分離: エンドユーザーに影響を与えることなく、`az ml online-deployment get-logs` を使用してログを検査するために、失敗しているデプロイメントのトラフィックを 0% に維持できます。トラフィックのロールバック方法 新しいデプロイメント (例: "green") でエラーが返された場合は、次の方法を使用して、トラフィックの 100% を既知の安定したデプロイメント (例: "blue") に再割り当てできます。

* Azure CLI: `az ml online-endpoint update` コマンドを使用してトラフィックの割合を設定します。

```
az ml online-endpoint update --name <your-endpoint-name> --traffic "blue=100 green=0"
```

* Azure Machine Learning Studio:

左側のメニューから「エンドポイント」を選択してください。

使用するリアルタイムエンドポイントを選択してください。

「詳細」または「ライブ交通情報」タブに移動してください。

トラフィックの割合を調整して、以前のデプロイメントが100%、失敗したデプロイメントが0%になるようにします。

変更をすぐに適用するには、「更新」または「保存」を選択してください。

参照 :

<https://learn.microsoft.com/en-us/answers/questions/1275110/azure-ml-v2-yaml-code-for-live-traffic-allocation>

質問: 44

チームは、複数の Azure Machine Learning パイプラインを使用してトレーニングジョブを実行します。

チームは、すべての実行において同じ Python パッケージとシステムライブラリが使用されることを保証しなければなりません。ソリューションは、トレーニングコードを変更することなく、依存関係の更新をバージョン管理できるものでなければなりません。

実行時の依存関係が一貫性があり、再利用可能になるようにワークスペースを設定する必要があります。

どの4つの行動を順番に実行すべきでしょうか？回答するには、行動リストから適切な行動を回答欄に移動させ、正しい順序に並べ替えてください。

Configure Azure Machine Learning pipelines	Answer Area
Reference the environment in training jobs and pipelines.	
Register the environment in the Azure Machine Learning workspace.	
Store dependency versions in a configuration file.	
Modify training scripts to install required packages at runtime.	
Define the required dependencies in an environment specification.	
Create a new version of the environment when dependencies change.	

正解:

Configure Azure Machine Learning pipelines

Answer Area

Reference the environment in training jobs and pipelines.
Register the environment in the Azure Machine Learning workspace.
Store dependency versions in a configuration file.
Modify training scripts to install required packages at runtime.
Define the required dependencies in an environment specification.
Create a new version of the environment when dependencies change.

Define the required dependencies in an environment specification.
Register the environment in the Azure Machine Learning workspace.
Create a new version of the environment when dependencies change.
Reference the environment in training jobs and pipelines.

Explanation:

ランタイムの依存関係の一貫性と再利用性を確保するには、まず、トレーニングコードに必要なすべての Python パッケージとシステム ライブラリをリストした conda.yaml または requirements.txt ファイルを作成します。このファイルは、ランタイムの唯一の信頼できる情報源となります。次に、Azure ML Python SDK v2 を使用して、名前と conda.yaml ファイルへの参照を指定して、ベースとなる Docker イメージを指定する Environment オブジェクトを作成します。その後、ml_client.environments.create_or_update を呼び出して Environment を登録し、自動的にインクリメントされるバージョンでワークスペース レジストリに公開します。最後に、すべてのパイプライン ジョブ ステップで、登録された環境を名前とバージョンで参照します。Azure ML は、キャッシュされた Docker イメージをビルドまたは取得し、それを実行コンテナとして使用します。この方法により、依存関係の更新には conda.yaml を変更して新しいバージョンを登録するだけで済み、トレーニングコード自体は変更されません。

Microsoft Learn リファレンス トピック: Azure Machine Learning 環境の作成と管理 - 再利用可能なキュレーション済み環境

Reference the environment in training jobs and pipelines.	Define the required dependencies in an environment specification.
Register the environment in the Azure Machine Learning workspace.	Register the environment in the Azure Machine Learning workspace.
Store dependency versions in a configuration file.	Create a new version of the environment when dependencies change.
Modify training scripts to install required packages at runtime.	Reference the environment in training jobs and pipelines.
Define the required dependencies in an environment specification.	
Create a new version of the environment when dependencies change.	

質問: 45

あるチームは、新たな企業向けAI機能の一環として、大規模な基盤モデルをMicrosoft Foundryに展開する計画を立てている。チーム組織内の様々な事業部門が、様々な社内アプリケーションからこのモデルにアクセスします。レイテンシを最小限に抑えながら、基盤となるモデルをデプロイする必要があります。どのデプロイメントタイプを使用すべきですか？

A. 開発者

- B. データゾーンバッチ
- C. データゾーン規格
- D. グローバルバッチ

正解: **C** ([コメントを发表する](#))

このシナリオでは、レイテンシを最小限に抑えるために、データゾーンスタンダードが最も適切な展開タイプです。

他のオプションは大量データ処理やテストのニーズに対応するものですが、データゾーンスタンダードは、パフォーマンスと地域的な可用性のバランスを取りながら、リアルタイムのアプリケーショントラフィック向けに特別に設計されています。

データゾーンスタンダードが正しい選択である理由

リアルタイム処理 : 「バッチ」オプションとは異なり、データゾーンスタンダードは内部アプリケーションからの同期的なリアルタイム要求に対応するように設計されており、インタラクティブなユーザーエクスペリエンスに必要な低遅延を保証します。

動的ルーティング : Microsoftが定義した特定のデータゾーン（米国やEUなど）内で、最も利用可能なデータセンターにトラフィックを動的にルーティングすることで、ある地域で負荷が高くなった場合でも応答性を維持するのに役立ちます。

より高いクォータ : 標準的な地域展開よりも高いデフォルトスループット (TPM/RPM) を提供するため、複数の事業部門が同時にモデルにアクセスしても、キューイングやレイテンシの急増を引き起こす可能性のある制限に達することはありません。

正しくない :

[Aではない]

開発者向け : このデプロイメントタイプは、多くの異なる事業部門がアクセスする高性能な本番ワークロードではなく、初期テスト、プロトタイプング、および実験に一般的に使用されます。

BでもDでもない

グローバルバッチとデータゾーンバッチ : これらは非同期型のデプロイメントタイプです。大規模なデータセット（文書の要約や大量の感情分析など）を24時間以内に処理するように設計されています。コストは50%削減できますが、即時応答が必要なリアルタイムアプリケーションには適していません。

参照 :

<https://learn.microsoft.com/en-us/azure/foundry/foundry-models/concepts/deployment-types>

質問: **46**

管理対象のオンラインエンドポイントに新しいモデルバージョンをデプロイします。トラフィックを10%に設定してテストを行い、レイテンシまたはエラー率がしきい値を超えた場合は自動的にロールバックする必要があります。どのような設定を行うべきでしょうか？

- A. テスト用の別エンドポイント
- B. 監視アラート付きトラフィック分割
- C. バッチエンドポイントの検証
- D. 手動テストワークフロー

正解: **B** ([コメントを发表する](#))

トラフィック分割により、リクエストの一部を新しいモデルバージョンに振り分けることで、新しいモデルバージョンの段階的な展開が可能になります。監視アラートと組み合わせることで、パフォーマンスが低下した際に自動的にロールバックすることもできます。個別のエンドポイントにはトラフィック管理機能が組み込まれておらず、シームレスな自動ロールバック機能は提供されません。

有効的なAI-300問題集はJPNTest.com提供され、AI-300試験に合格することに役に立ちます！JPNTest.comは今最新AI-300試験問題集を提供します。JPNTest.com AI-300試験問題集はもう更新されました。ここでAI-300問題集のテストエンジンを手に入れます。最新版のアクセス、<https://www.jpntest.com/shiken/AI-300-mondaishu> 126問、30%ディスカウント、特別な割引コード: **JPNshiken**」

質問: 47

顧客からのフィードバックを分析するために、基本言語モデルを微調整しています。

サポートチケットの例にラベルを付けます。Microsoft Foundry の基本モデルを構成および微調整することで、分類精度を向上させる必要があります。

設定を行い、微調整を実行する必要があります。

まず最初に何をすべきでしょうか？

- A. プロンプトフローを使用して、評価用の複数のプロンプトテンプレートを生成します。
- B. 微調整を開始する前に、ベースモデルをオンラインエンドポイントにデプロイします。
- C. 評価パイプライン内のすべての推論呼び出しのトレースを有効にします。
- D. データセットをプロンプトと補完のペアを含む JSONL ファイルとしてフォーマットし、ファイルをアップロードします。

正解: **C** ([コメントを发表する](#))

ファインチューニングはデータ駆動型のプロセスであり、適切な形式のデータセットがないと、ファインチューニング ジョブの設定や実行を開始することはできません。Microsoft のドキュメントには、Microsoft Foundry または Azure OpenAI Studio でファインチューニング ジョブを開始する前に、トレーニング データがプロンプトと完了のペアを含む JSONL 形式である必要があることが明記されています。オプション A (プロンプト フロー テンプレート) は、プロンプト エンジニアリングがファインチューニング前のステップであるため、この段階では関係ありません。オプション B (最初にベース モデルをデプロイする) は誤りです。ファインチューニングでは、事前のデプロイを必要とせずにベース モデルの重みをトレーニングします。オプション C (評価パイプラインでトレースを有効にする) は、デプロイ後の可観測性ステップであり、ファインチューニングの前提条件ではありません。データセットの準備とアップロードは、ファインチューニング ワークフローの基本的な最初のステップです。適切な形式のデータがないと、他のステップに進むことはできません。

Microsoft Learn リファレンス トピック: Azure AI Foundry でモデルを微調整する - トレーニング データセットを準備する

質問: 48

実験結果の一貫性を確保できるような、実験追跡戦略を提案する必要があります。

何をすすめますか？

- A. Azure Machine Learning ジョブの出力ログ
- B. MLflow実験追跡
- C. Application Insights ログ
- D. Azure Monitor アラート

正解: ([正解を表示します](#))

MLflow は、実験追跡のための業界標準のオープンソース プラットフォームであり、Azure Machine Learning はこれと一流のネイティブ統合を実現しています。Azure ML ジョブ内で MLflow を使用すると、パラメーター、メトリック、および成果物が AML ワークスペースの実行履歴に自動的に記録されるため、すべての実行が再現可能で比較可能になります。オプション A (AML ジョブ出力ログ) はコンソール出力のみをキャプチャし、構造化されたパラメーターとメトリックのログ記録がありません。オプション C (Application Insights ログ) は、アプリケーション レベルのテレメトリ用に設計されており、ML 実験メタデータ用ではありません。オプション D (Azure Monitor アラート) は、追跡システムではなく、リアクティブ通知ツールです。MLflow の自動ログ記録機能により、scikit-learn、XGBoost、PyTorch などの一般的なフレームワークでは、カスタム コードを 1 行も記述することなくパラメーターとメトリックがキャプチャされ、Fabrikam の一貫した実験追跡の要件に直接対応します。

Microsoft Learn リファレンス トピック: MLflow を使用して ML 実験を追跡する - Azure Machine Learning MLflow 統合

質問: 49

データセット、コード、環境を含む実験の完全な再現性を、複数の実行およびワークスペースにわたって確保する必要があります。どの組み合わせが最も適切でしょうか？

- A. Gitのみ
- B. データセットのバージョン管理のみ
- C. 環境 + データセット + コードバージョン管理
- D. メトリクスのみログ記録

正解: ([正解を表示します](#))

再現性を確保するには、コード、データセット、環境といったすべての構成要素にバージョン管理が必要です。これらの要素のいずれかが欠けていると、実験を正確に再現することはできません。例えば、同じコードでもデータや依存関係が異なると結果が異なり、デバッグや監査が困難になります。

有効的な**AI-300**問題集はJPNTTest.com提供され、**AI-300**試験に合格することに役に立ちます！JPNTTest.comは今最新**AI-300**試験問題集を提供します。JPNTTest.com AI-300試験問題集はもう更新されました。ここで**AI-300**問題集のテストエンジンを手に入れます。最新版のアクセス、<https://www.jpntest.com/shiken/AI-300-mondaishu> **126**問、**30%**ディスカウント、特別な割引コード: **JPNshiken**」