



Data Engineering on Google Cloud Platform

Description

Prix : 2 800 € HT

Durée : 4 jours

Code de Référence : GCP200DE

Catalogue Google Cloud Platform

Cette formation de quatre jours dirigé par un instructeur offre aux participants une introduction pratique à la conception et à la création de systèmes de traitement des données sur Google Cloud Platform. Grâce à une combinaison de présentations, de démonstrations et de travaux pratiques, les participants apprendront à concevoir des systèmes de traitement des données, à construire des pipelines de données de bout en bout, à analyser les données et à effectuer un apprentissage automatique. Le cours couvre les données structurées, non structurées et en streaming.

Objectifs de la formation

Cette formation GCP permet aux participants d'acquérir les compétences suivantes:

- Conception et déploiement de pipelines et d'architectures pour le traitement des données
- Création et déploiement de workflows de machine learning
- Interrogation des ensembles de données
- Visualisation des résultats des requêtes et création de rapports

Public

Cette formation Google Cloud Platform s'adresse aux développeurs expérimentés qui sont responsables de la gestion des transformations des mégadonnées, notamment: l'extraction, le chargement, la transformation, le nettoyage et la validation des données.

Cette formation est accessible aux personnes en situation de handicap, contactez-nous



pour en savoir plus.

Prérequis

Pour tirer le meilleur parti de ce cours, les participants doivent disposer des éléments suivants :

- Avoir suivi le cours Google Cloud Fundamentals: Big Data & Machine Learning ou avoir une expérience équivalente
- Compétence de base avec un langage de requête commun tel que SQL
- Expérience avec la modélisation de données et l'ETL
- Développement d'applications à l'aide d'un langage de programmation commun tel que Python
- Connaissance du machine learning et / ou des statistiques

Compréhension de l'anglais et du vocabulaire anglais spécifique IT.

Vous souhaitez faire vérifier vos prérequis ? Contactez-nous pour l'organisation d'un entretien téléphonique avec un de nos consultants formateurs.

Pour une efficacité renforcée, le nombre de participants est limitée à 12. Le maintien des sessions est conditionné à un minimum de 3 participants.

Programme de la formation

Module 1 : Introduction à l'ingénierie des données

- Explorez le rôle d'un data engineer
- Analyser les défis d'ingénierie des données
- Introduction à BigQuery
- Data lakes et data warehouses
- Démo : requêtes fédérées avec BigQuery
- Bases de données transactionnelles vs data warehouses
- Démo : recherche de données personnelles dans votre jeu de données avec l'API DLP
- Travailler efficacement avec d'autres équipes de données
- Gérer l'accès aux données et gouvernance
- Construire des pipelines prêts pour la production
- Etude de cas d'un client GCP



Lab : Analyse de données avec BigQuery

Module 2 : Construire un Data Lake

- Introduction aux data lakes
- Stockage de données et options ETL sur GCP
- Construction d'un data lake à l'aide de Cloud Storage
- Démo : optimisation des coûts avec les classes et les fonctions cloud de Google Cloud Storage
- Sécurisation de Cloud Storage
- Stocker tous les types de données
- Démo : exécution de requêtes fédérées sur des fichiers Parquet et ORC dans BigQuery
- Cloud SQL en tant que data lake relationnel

Module 3 : Construire un Data Warehouse

- Le data warehouse moderne
- Introduction à BigQuery
- Démo: Requête des TB + de données en quelques secondes
- Commencer à charger des données
- Démo: Interroger Cloud SQL à partir de BigQuery

Lab : Chargement de données avec la console et la CLI

- Explorer les schémas
- Exploration des jeux de données publics BigQuery avec SQL à l'aide de INFORMATION_SCHEMA
- Conception de schéma
- Démo : Exploration des jeux de données publics BigQuery avec SQL à l'aide de INFORMATION_SCHEMA
- Champs imbriqués et répétés dans BigQuery

Lab : tableaux et structures

- Optimiser avec le partitionnement et le clustering
- Démo : Tables partitionnées et groupées dans BigQuery
- Aperçu : Transformation de données par lots et en continu



Module 4 : Introduction à la construction de pipelines de données par lots EL, ELT, ETL

- Considérations de qualité
- Comment effectuer des opérations dans BigQuery
- Démo : ELT pour améliorer la qualité des données dans BigQuery
- Des lacunes
- ETL pour résoudre les problèmes de qualité des données

Module 5: Exécution de Spark sur Cloud Dataproc

- L'écosystème Hadoop
- Exécution de Hadoop sur Cloud Dataproc GCS au lieu de HDFS
- Optimiser Dataproc

Lab : Exécution de jobs Apache Spark sur Cloud Dataproc

Module 6 : Traitement de données sans serveur avec Cloud Dataflow

- Cloud Dataflow
- Pourquoi les clients apprécient-ils Dataflow?
- Pipelines de flux de données

Lab : Pipeline de flux de données simple (Python / Java)

Lab : MapReduce dans un flux de données (Python / Java)

Lab : Entrées latérales (Python / Java)

- Templates Dataflow
- Dataflow SQL

Module 7 : Gestion des pipelines de données avec Cloud Data Fusion et Cloud Composer

- Création visuelle de pipelines de données par lots avec Cloud Data Fusion: composants, présentation de l'interface utilisateur, construire un pipeline, exploration de données en utilisant Wrangler

Lab : Construction et exécution d'un graphe de pipeline dans Cloud Data Fusion

- Orchestrer le travail entre les services GCP avec Cloud Composer – Apache Airflow



Environment: DAG et opérateurs, planification du flux de travail

- Démo : Chargement de données déclenché par un événement avec Cloud Composer, Cloud Functions, Cloud Storage et BigQuery

Lab : Introduction à Cloud Composer

Module 8 : Introduction au traitement de données en streaming

- Traitement des données en streaming

Module 9 : Serverless messaging avec Cloud Pub/Sub

- Cloud Pub/Sub

Lab : Publier des données en continu dans Pub/Sub

Module 10 : Fonctionnalités streaming de Cloud Dataflow

- Fonctionnalités streaming de Cloud Dataflow

Lab : Pipelines de données en continu

Module 11 : Fonctionnalités Streaming à haut débit BigQuery et Bigtable

- Fonctionnalités de streaming BigQuery

Lab : Analyse en continu et tableaux de bord

- Cloud Bigtable

Lab : Pipelines de données en continu vers Bigtable

Module 12 : Fonctionnalité avancées de BigQuery et performance

- Analytic Window Functions
- Utiliser des clauses With
- Fonctions SIG
- Démo : Cartographie des codes postaux à la croissance la plus rapide avec BigQuery GeoViz
- Considérations de performance

Lab : Optimisation de vos requêtes BigQuery pour la performance



Lab : Création de tables partitionnées par date dans BigQuery

Module 13 : Introduction à l'analytique et à l'IA

- Qu'est-ce que l'IA?
- De l'analyse de données ad hoc aux décisions basées sur les données
- Options pour modèles ML sur GCP

Module 14 : API de modèle ML prédéfinies pour les données non structurées

- Les données non structurées sont difficiles à utiliser
- API ML pour enrichir les données

Lab : Utilisation de l'API en langage naturel pour classer le texte non structuré

Module 15 : Big Data Analytics avec les notebooks Cloud AI Platform

- Qu'est-ce qu'un notebook
- BigQuery Magic et liens avec Pandas

Lab : BigQuery dans Jupyter Labs sur IA Platform

Module 16 : Pipelines de production ML avec Kubeflow

- Façons de faire du ML sur GCP
- Kubeflow AI Hub

Lab : Utiliser des modèles d'IA sur Kubeflow

Module 17 : Création de modèles personnalisés avec SQL dans BigQuery ML

- BigQuery ML pour la construction de modèles rapides
- Démo : Entraîner un modèle avec BigQuery ML pour prédire les tarifs de taxi à New York
- Modèles pris en charge

Lab : Prédire la durée d'une sortie en vélo avec un modèle de régression dans BigQuery ML

Lab : Recommandations de film dans BigQuery ML



Module 18 : Création de modèles personnalisés avec Cloud AutoML

- Pourquoi Auto ML?
- Auto ML Vision
- Auto ML NLP
- Auto ML Tables

Méthodes pédagogiques

Des exercices pratiques et des démonstrations vous permettront de mettre en pratique les notions théoriques présentées.

La dernière version du support de cours, en anglais, vous est transmise par voie dématérialisée. Les cours seront disponibles en ligne pendant 730 jours après leur activation et téléchargeables avec Bookshelf application. Pour y accéder, il est nécessaire de créer un compte eVantage sur evantage.gilmoreglobal.com.

Méthodes d'évaluation des acquis

Afin d'évaluer l'acquisition de vos connaissances et compétences, il vous sera envoyé un formulaire d'auto-évaluation, qui sera à compléter en amont et à l'issue de la formation. Un certificat de réalisation de fin de formation est remis au stagiaire lui permettant de faire valoir le suivi de la formation.