

Diploma

# ADVANCED DATA ENGINEER



## Presentación

El Diploma Advanced Data Engineer te preparará y potenciará tus habilidades en ingeniería de datos, permitiéndote dominar las técnicas para la mejora y optimización de sistemas dedicados que soporten Data Warehouse y Big Data, así como diseñar e implementar soluciones en la nube bajo el enfoque Data Fabric, que permite crear una única fuente de verdad organizacional, integrando y consolidando todos los silos de información.



## Sobre este Diploma

**37**

sesiones

**144**

horas  
académicas

**47**

talleres  
prácticos

**01**

proyecto para  
tu portafolio

## ¿Cómo impulsamos tu carrera?

- Sesiones 80% **enfocadas en la práctica.**
- Enfoque en **Casos Reales** enfrentando los retos del mercado.
- Énfasis en **habilidades técnicas y blandas.**
- **Mentoría especializada** con docentes praticioners.
- Acompañamiento **constante.**

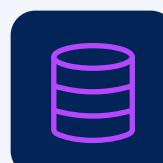


## ¿Porqué estudiar este diploma?

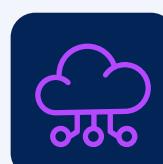
**Lleva tu potencial en ingeniería de datos a su máximo nivel y lidera el desarrollo de soluciones robustas que integren todos los datos de la organización y basadas en el enfoque Data Fabric.**



Culmina tu capacitación con una solución avanzada de ingeniería de datos construida por ti mismo.



Aprende a mejorar y a optimizar sistemas dedicados (on-premise) que operen sobre SQL Server, así como aquellos basados en Apache Spark (Big Data).



Aprende a diseñar e implementar soluciones Data Fabric sobre las plataformas cloud líderes del mercado: Azure, AWS y GCP.

## ¿En qué se diferencia esta versión respecto al tradicional Diploma Data Engineer?

- Este Diploma se orienta al scraping de datos avanzado mediante el enfoque y características de la librería Selenium, que ofrece mayores prestaciones y parámetros de configuración para proyectos más robustos.
- Este Diploma se orienta a la optimización y performance de repositorio de datos en entornos dedicados, como son Data Warehouse y Data Lakes, en vez de su diseño o implementación básica.
- Este Diploma emplea las plataformas cloud para la implementación de arquitecturas de datos basadas en el enfoque Data Fabric.
- Este Diploma se orienta a la orquestación de entornos dedicados y entornos cloud mediante la plataforma de Apache Airflow.



# Objetivo del diploma

- Comprende el impacto que tiene el desarrollo de su marca personal para su vida profesional.
- Implementa Data Warehouses de tres capas automatizados con paquetes SSIS.
- Utiliza Python para la implementación de componentes para soluciones de ingeniería de datos.
- Aplica técnicas en el entorno Apache Spark para garantizar la velocidad de respuesta y la optimización de recursos de cómputo en la ejecución de ETL que operan sobre un entorno Big Data.
- Implementa soluciones de ingeniería de datos en el entorno de Ms. Azure, AWS Cloud y GCP.
- Utiliza Apache AirFlow para la implementación y calendarización de tareas

## Objetivo Final

El alumno desarrolla una solución de ingeniería de datos con dos características generales a) híbrida, es decir que integra entornos dedicados (on-premise) y cloud, y b) basada en Data Fabric, la misma que el alumno construye en un entorno Azure, AWS o GCP.

# ¿A quién está dirigido?

## 1. Ingenieros de datos junior y semi-senior

Profesionales que actualmente desempeñen este rol, y busquen:

- Optimizar sus entornos de datos dedicados, tanto Data Warehouses sobre SQL Server como Big Data sobre Apache Spark.
- Llevar sus pipelines de datos construidos en Cloud a un enfoque Data Fabric y orquestarlos con sus sistemas locales.

## 2. Analistas y científicos de datos con perfiles técnicos relacionados a las carreras de informática, sistemas o afines

Personas que desempeñen alguno de estos roles, y busquen:

- Migrar a puestos abocados al diseño e implementación de pipelines de datos y ETLs.

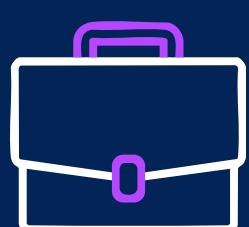


# ¿Cuáles son los requisitos?



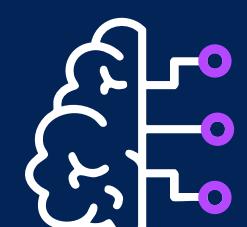
## Conocimientos / Habilidades

- Conocimiento de programación en lenguaje Python (nivel avanzado)
- Conocimiento de operación y gestión de entornos Big Data.
- Conocimiento de plataforma cloud y gestión de servicios.



## Experiencia Laboral

- Mínimo un año de experiencia laboral como ingeniero de datos o haciendo sus veces.



## Tecnológicos

- Contar con una laptop o computadora de escritorio con disponibilidad de micrófono y cámara web.
- Tener instalado los softwares y herramientas señalados en la sección Contenidos.

## Perfil del egresado

El egresado del Diploma Advanced Data Engineer estará en la capacidad de implementar soluciones de ingeniería de datos que integran sistemas dedicados (on-premise) y en nube sobre alguna de las plataformas líderes del mercado como Azure, AWS o GCP, considerando técnicas avanzadas para la ingestión de datos y control de performance.

## Campo Laboral

El egresado del Diploma Advanced Data Engineer podrá laborar en puestos relacionados a:

- Ingeniero de datos / Data Engineer
- Ingeniero de datos cloud / Cloud Data Engineer.
- Big Data Engineer.

## Herramientas



Google Colab



Apache Spark



Azure



AWS



SQL Server



Google Cloud Platform



Apache Airflow



# Malla Curricular

## I. Taller de Marca y Empleabilidad

- Actividad de sociabilización y contacto.
- Marca personal ¿Qué es y cómo desarrollarla?
- Empleabilidad y ser empleable. Diferencias clave.
- ¿Cómo hacer más atractivo el currículum?
- ¿Cómo afrontar una entrevista de trabajo?

## II. Diseño de Data Warehouses avanzados con SQLSERVER y SSIS

### 1. Arquitectura y modelamiento de componentes de ingeniería de datos

- Modelamiento dimensional: Star & Snowflake schemas.
- Arquitectura moderna de Data Warehouses.
- Arquitectura moderna de Data Lakes.
- Arquitectura moderna de Data Lakehouses.

### 2. Implementación de Data Warehouses avanzados (SQLSERVER + SSIS)

- Introducción a SQL Server Integration Services (SSIS).
- **Taller:** Diseño de ETL básicos con SSIS.
- **Taller:** Implementación de DWH con SQL Server: Capa Stage.
- **Taller:** Implementación de DWH con SQL Server: Capa Operational Data Store (ODS).
- **Taller:** Implementación de DWH con SQL Server: Capa Business Data Store (BDS).
- **Taller:** Automatización de DWH con paquetes SSIS y jobs.

### 3. Configuración de Data Warehouses avanzados

- Técnicas de Ingesta de datos: Change Data Capture (CDC), Delta ingestion, Full ingestion.
- **Taller:** Implementación de las técnicas de ingestión de datos con SQL Server.
- Técnicas de optimización del rendimiento del almacenamiento: Indexing, partitioning, bucketing, design by query, clustering).
- **Taller:** Implementación de las técnicas de optimización con SQL Server.

## III. Ingesta y procesamiento avanzado con Python

### 4. Control de bases de datos

- Repaso de principales librerías para procesamiento de datos.
- ORM SQLAlchemy. Definición, usos en ingeniería de datos.
- **Taller:** Diseño de un ETL sencillo con pandas y SQLAlchemy.

## 5. Control de concurrencia de datos

- IO-Bound vs. CPU-Bound. Aplicaciones en ingeniería de datos.
- El método ThreadPoolExecutor de Python. Casos de uso, secuencia de implementación.
- **Taller:** Uso de ThreadPoolExecutor para procesamiento paralelo de archivos.
- **Taller:** Uso de ThreadPoolExecutor para carga de datos desde un API.
- **Taller:** Uso de ThreadPoolExecutor para ejecución en paralelo de consultas a bases de datos.
- **Taller:** Solución E2E, de API a base de datos relacional.

## 6. Scraping avanzado con Selenium

- Fundamentos Web Scraping.
- La librería Selenium. Casos de uso, características.
- Cómo evitar las trampas en el proceso del Web Scraping (Ajustando encabezados, Manejo de cookies con JavaScript, Huellas dactilares TLS, Timing Is Everything).
- Expresiones regulares.
- Web Scraping in Parallel.
- Web Scraping Proxies.
- **Taller:** Obtener datos de un archivo PDF utilizando expresiones regulares.
- **Taller:** Web Scraping a sitios web.

## IV. Optimización de procesos Big Data

### 7. Repaso Apache Spark en Ingeniería de datos

- Big Data en proyectos de ingeniería de datos.
- Apache Spark para Big Data.
- Apache Spark. Módulo, Dataframe API y PySpark Functions.
- **Taller:** Implementación de un ETL básico con PySpark.

### 8. Apache Spark for Tuning and Performance

#### Analís de consultas Spark

- El Spark Query Plan. Definición, uso en la etapa de optimización de Spark.
- **Taller:** Creación e interpretación de Spark Query Plan.
- **Taller:** Creación e interpretación de Spark DAGs.

#### Ajuste de recursos

- **Taller:** Monitoreo y ajuste del consumo de memoria con Spark UI (Memory management)
- **Taller:** Ajuste de ejecutores para la optimización de memoria y núcleos (Executor tuning).
- **Taller:** Ajuste de particiones para la optimización de disco y red.

# Malla Curricular

## Optimización avanzada

- **Taller:** Mejora de rendimiento basada en partitioning (particionamiento lógico).
- **Taller:** Mejora de rendimiento basada en Buckets.
- **Taller:** Mejora basada en Caching (memoria caché).
- **Taller:** Mejora basada en balance de carga de nodos (Solve Data Skew). Salting, Broadcast joins.
- **Taller:** Mejora basada en reducción dinámica de particiones de datos (Dynamic Partition Pruning).

## V. Azure para ingeniería de datos

### 9. Fundamentos de ingeniería de datos con Azure

- Principales Servicios de Azure para Ingeniería de datos. Denominación y modelos de costo asociados.

### 10. Arquitectura "Data Fabric" en Azure

- Visión Integral de la Arquitectura Data Fabric.
- Enfoques arquitectónicos Data Fabric y Data Mesh.
- Servicios de Azure asociados a Data Fabric.

#### Discovering & Ingest

- Planteamiento de la casuística a resolver.
- **Taller:** Revisión de orígenes de datos y elaboración del catálogo de datos con Azure Data Catalog.
- **Taller:** Configuración de Azure Data Factory para ingestar datos de diversas fuentes.

#### Data Lakehousing

- Introducción a los servicios Azure Blob Storage y Storage Account.
- **Taller:** Implementación de un Data Lake con Azure Data Lake Storage. Integración con Data Factory.

#### Big Data Pipeline

- Introducción a Databricks y Azure Databricks.
- **Taller:** Uso de Azure Databricks para crear un pipeline para procesar y transformar lo almacenado en el Data Lake.

#### Data Warehousing

- Introducción a Azure Synapse Analytics.
- **Taller:** Uso de Azure Synapse Analytics para implementar un Data Warehouse. Integración con Azure Databricks para consumo de datos del Data Lake.

#### Data Deliver

- Introducción a Azure Analysis Services.
- **Taller:** Uso de Azure Analysis Services para implementar un Datamart. Integración con Azure Synapse Analytics.
- **Taller:** Conexión con Power BI y test de funcionamiento.

## VI. AWS para ingeniería de datos

### 11. Fundamentos de ingeniería de datos con AWS

- Principales Servicios de AWS para Ingeniería de datos. Denominación y modelos de costo asociados.

### 12. Arquitectura Data Fabric en AWS

- Servicios de AWS asociados a Data Fabric.

#### Discovering & Ingest

- Planteamiento de la casuística a resolver.
- **Taller:** Revisión de orígenes de datos y elaboración del catálogo de datos con AWS Glue Data Catalog.
- **Taller:** Configuración de AWS Glue DataBrw y AWS Glue para ingestar datos de diversas fuentes.

#### Data Lakehousing

- Introducción al servicio S3 y seguridad en Buckets.
- **Taller:** Implementación de un Data Lake mediante instancias S3. Integración con Glue.

#### Big Data Pipeline

- Introducción al servicio AWS EMR.
- **Taller:** Uso de AWS EMR para crear un pipeline para procesar y transformar lo almacenado en el Data Lake.

#### Data Warehousing

- Introducción a Amazon Redshift.
- **Taller:** Uso de Amazon Redshift para implementar un Data Warehouse. Integración con EMR.

#### Data Deliver

- **Taller:** Revisión general de Amazon QuickSight.
- **Taller:** Test de conexión desde Power BI.

## VII. GCP para ingeniería de datos

### 13. Fundamentos de ingeniería de datos con GCP

- Principales Servicios de GCP para Ingeniería de datos.

### 14. Arquitectura Data Fabric en GCP

#### Discovering & Ingest

- Planteamiento de la casuística a resolver.
- Introducción a los servicios para ingesta de datos: Cloud Data Fusion, Cloud Dataflow y Pub/Sub.
- **Taller:** Configuración de Cloud Data Fusion para ingestar datos de diversas fuentes.

#### Data Lakehousing

- El servicio Cloud Storage y la gestión de su seguridad.
- **Taller:** Implementación de un Data lake mediante Cloud Storage.

# Malla Curricular

## **Big Data Pipeline**

- Introducción a Dataproc.
- **Taller:** Uso de Dataproc para procesar y transformar lo almacenado en el Data lake.

## **Data Warehousing**

- Introducción a BigQuery.
- **Taller:** Uso de BigQuery para implementar un Data Warehouse. Integración con Dataproc.

## **Data Deliver**

- **Taller:** Revisión general de BigQuery BI Engine.
- **Taller:** Test de conexión desde Power BI.

## **VIII. Entornos híbridos: Dedicados y Cloud**

### **15. Introducción a Apache AirFlow**

- Apache Airflow. Definición, casos de uso en ingeniería de datos.
- Estructura de un notebook de Airflow.
- **Taller:** Implementación y calendarización de una tarea que carga de datos desde una API de clima.

### **16. Apache AirFlow para ingeniería de datos**

- **Taller:** Implementación y calendarización de una tarea para carga y transformación de datos de SQL Server local a servicio de almacenamiento Azure.

## **IX. Proyecto integrador**

### **1. Componente: Data Warehouse de la solución - Módulo II**

- Implementado con SQL Server.
- Una técnica de ingesta de datos.
- Aplicación de dos técnicas de optimización (mínimo).

### **2. Componente: Ingesta de datos de la solución - Módulo III**

- Implementado con código Python.
- Ingesta basada en API.
- Ingesta basada en Scraping.
- Por lo menos uno de ellos con ThreadPoolExecutor.

### **3. Componente: ETLs optimizados sobre Apache Spark (Big Data) - Módulo IV**

- Implementados con código Python y PySpark.
- Aplicación de dos técnicas de optimización (mínimo).

### **4. Componente: Data Fabric en Ms. Azure - Módulo V**

- Flujo completo ajustado a los recursos y objetivos del proyecto.

### **5. Componente: Data Fabric en AWS - Módulo VI**

- Flujo completo ajustado a los recursos y objetivos del proyecto.

### **6. Componente: Data Fabric en GCP - Módulo VII**

- Flujo completo ajustado a los recursos y objetivos del proyecto.

### **3. Componente: AirFlow Scheduled Pipeline - Módulo VIII**

- Implementado con Apache Airflow.
- Debe realizar cargas programadas del entorno dedicado (on-premise) a Data Fabric.

# Certificación DMC

Por aprobación del Diploma Advanced Data Engineer, por un total de 144 horas académicas.



## Nuestra Propuesta de Capacitación

### Las metodologías que aplicamos



Desarrollo de competencias clave en el mundo de los datos

Analiza • Innova • Transforma



Aprendizaje Secuencial

- Descubre conocimiento de vanguardia
- Explora con la guía del experto
- Aplica lo aprendido



Aprendizaje basado en práctica (Learning by Doing)

- Resuelve retos
- Aprende en base a proyectos
- Analiza casos



## Certificación Internacional

Al finalizar la capacitación, tendrás la oportunidad de acceder al

# AWS CERTIFIED DATA ENGINEER - ASSOCIATE

con un descuento especial

Costo del examen  
**150 dólares**

**50%**

Precio con descuento  
**75 dólares**



# Certificación Internacional

Al finalizar la capacitación, tendrás la oportunidad de acceder al **Big Data Professional Certification (BDPC)** de CertiProf con un descuento especial.



## IMPORTANTE:

### • No es una certificación automática de CertiProf

Completar la capacitación no garantiza automáticamente el certificado de CertiProf, es un paso previo, pero no sustituye el proceso oficial de certificación.

### • Aprueba la capacitación y activa tu beneficio

El primer paso para acceder al beneficio es aprobar la capacitación. ¡Superarlo te abre la puerta!

### • Tú eliges si aplicar o no

El beneficio es opcional. Solo tú puedes decidir aprovecharlo

### • Más de una oportunidad para alcanzar tu meta

Con el beneficio, tendrás hasta 2 intentos para rendir el examen y asegurar que tu esfuerzo sea recompensado con la certificación.

## Docentes Expertos



**Miguel  
Balcazar**

Senior Lead, Data  
Engineering  
*en KYNDRYL*



**Maria  
Moran**

Employability Analyst  
*en PRONABEC*



**Antony  
Alza**

Analista Sr. de  
Ingeniería Financiera  
*en ALICORP*



**Tony  
Trujillo**

Arquitecto de datos  
*en IDATHA*



**Miguel  
García**

Especialista en TI  
*en E2E SOLUTIONS*



**Angel  
Tintaya**

Senior Data Engineer  
*en TRANZACT*



**Gustavo  
Rangel**

Google Cloud Platform  
Specialist  
*en GOOGLE*



**Importante:**

En caso de contingencias podría cambiar alguno de los docentes por otro profesional de similar perfil.

# ¿Por qué elegirnos?

**+16**

Más de 16 años  
de experiencia.

**+300**

Más de 300 empresas  
asesoradas en Perú,  
Ecuador y Bolivia.

**35k**

35 mil profesionales  
capacitados en más de 20  
países de América Latina.



Propuesta integra  
en formación en  
Data & AI.

**+150**

Más de 150 docentes  
expertos de Latinoamérica,  
España y Estados Unidos.



Comunidad más grande en Data & AI  
con beneficios exclusivos:  
Networking, empleabilidad,  
habilidades blandas.



Excelente nivel de  
servicio.



## Nuestros Partners

CertiProf® | Partner

Google Partners



## Estas empresas confían en nosotros



BBVA



ANTAMINA



PROM PERÚ



SCOTIABANK



PACÍFICO  
SEGUROS



SUNAT



CAJA  
HUANCAYO



BUENAVENTURA



PRONABEC



CAJA  
AREQUIPA



RIMAC



BCRP



MIBANCO



MAPFRE



ONCOSALUD



LOS ANDES

# Métodos de pago

**J&J DATA MINING CONSULTING S.A.C.**  
RUC: 20520972740

## 1. Depósito en cuenta BCP

- Corriente soles BCP: **193-225-1181-0-01**
- CCI BCP: **00219300225118100116**
- Corriente BCP dólares: **193-2318515-1-52**
- CCI BCP dólares: **002-193-002318515152-11**

## 2. Depósito en cuenta BBVA

- Ahorros BBVA soles: **0011-0177-02-00180473**
- CCI BBVA: **011-177-000200180473-37**

## 2. Pago Online

Generamos un link de pago online donde se acepta todas las tarjetas.

## 3. Pago con Yape

A nombre de J J Data  
Mining Consulting Sac



## 4. Pago online por PayPal



**06 CUOTAS SIN INTERESES** pagando con:





**Visita nuestra web**

[www.dmc.pe](http://www.dmc.pe)