



UNIVERSITÀ  
DEGLI STUDI DI MILANO-BICOCCA

## COURSE SYLLABUS

### Technological Infrastructures for Data Science

2526-2-FDS01Q016

---

#### Obiettivi

##### Conoscenza e capacità di comprensione

Al termine del corso, lo studente avrà acquisito:

- Conoscenze fondative delle principali soluzioni tecnologiche a supporto della data science, includendo virtualizzazione, cloud computing e containerization
- Comprensione dei modelli architetturali di riferimento per le infrastrutture di data science, con particolare focus su Data Lake, HDFS e YARN
- Conoscenze teoriche sui paradigmi di processamento dati (batch processing, stream processing, messaging) e relative tecnologie (Hadoop, Spark, Storm, Kafka)
- Comprensione delle metodologie di sviluppo software moderne (Waterfall, Agile, DevOps, DataOps, MLOps) nel contesto della data science
- Conoscenze di base per analizzare e valutare la possibilità di applicare soluzioni infrastrutturali esistenti a problemi specifici di data science

##### Conoscenza e capacità di comprensione applicate

Al completamento del corso, lo studente sarà in grado di:

- Progettare e implementare soluzioni di containerization utilizzando Docker per applicazioni di data science
- Utilizzare strumenti e piattaforme cloud per la gestione e l'elaborazione di grandi volumi di dati
- Configurare e utilizzare sistemi distribuiti per il batch e stream processing di dati
- Applicare metodologie di sviluppo software appropriate ai progetti di data science e machine learning
- Sperimentare con soluzioni tecniche e tecnologiche specifiche attraverso attività laboratoriali pratiche
- Interagire efficacemente con gli strumenti tecnologici presentati durante il corso

##### Competenze trasversali

Il corso contribuisce allo sviluppo delle seguenti competenze trasversali:

**Autonomia di giudizio:** attraverso l'analisi critica di diverse soluzioni tecnologiche e la valutazione della loro applicabilità a contesti specifici di data science.

**Abilità comunicative:** mediante la discussione orale di approfondimenti su tematiche del corso e la capacità di presentare soluzioni tecniche in modo chiaro e strutturato.

**Capacità di apprendere:** fornendo gli strumenti metodologici per rimanere aggiornati sull'evoluzione delle tecnologie per la data science e per approfondire autonomamente nuove soluzioni infrastrutturali.

## Contenuti sintetici

### Sezioni Tematiche

Il corso è costituito dai seguenti moduli:

**Modulo 1 - Infrastruttura:** Introduzione alla virtualizzazione, Cloud Computing e Containerization

**Modulo 2 - Piattaforma:** Organizzazione e distribuzione dei dati, Data Lake, HDFS, YARN

**Modulo 3 - Processamento:** Batch vs Streaming vs Messaging, i casi di Hadoop, Spark, Storm, Kafka

**Modulo 4 - Sviluppo software:** Waterfall, Agile, DevOps, DataOps, MLOps

## Programma esteso

Argomenti del corso divisi per moduli:

### Modulo 1 - Infrastruttura

- La figura del data engineer
- L'architettura di riferimento
- Virtualizzazione
- Cloud Computing (Introduzione, Modelli di servizio e di deployment, caratteristiche essenziali)
- Containerization con Docker
- Serverless

### Modulo 2 - Piattaforma

- Il Data Lake
- HDFS e YARN

### Modulo 3 - Processamento

- Batch processing (Apache Hadoop e Apache Spark)
- Stream processing (Apache Storm, Apache Spark e Apache Flink)

- Messaging (Apache Kafka)

## Modulo 4 - Sviluppo Software

- Service computing
- Software engineering
- Metodologie di sviluppo (Waterfall, Agile, DevOps, DataOps, MLOps)

### Prerequisiti

#### Conoscenze tecniche fondamentali

- **Architettura dei sistemi informatici:** comprensione dell'organizzazione e del funzionamento dei componenti hardware (processore, memoria RAM, dispositivi di archiviazione) e della loro interazione
- **Sistemi operativi:** familiarità con i concetti base e l'utilizzo pratico di ambienti Unix/Linux o Windows
- **Interfaccia a riga di comando:** competenza nell'uso della shell/terminale per navigazione del filesystem, gestione file e esecuzione di comandi base

#### Competenze di programmazione

- **Linguaggio Python:** conoscenza delle strutture dati fondamentali (liste, dizionari, tuple), costrutti di controllo (cicli, condizioni), funzioni e gestione base di librerie
- **Ambiente Jupyter:** esperienza nell'utilizzo di Jupyter Notebook/Lab per sviluppo interattivo, visualizzazione dati e documentazione del codice

### Livello richiesto

Le competenze elencate dovrebbero corrispondere a quelle acquisite in corsi introduttivi di informatica o programmazione a livello undergraduate, o attraverso esperienza pratica equivalente.

### Modalità didattica

Il corso adotta un approccio didattico integrato che combina diverse metodologie per favorire l'apprendimento attivo e il coinvolgimento degli studenti:

### Articolazione delle attività

#### Lezioni frontali interattive

- Circa 15 lezioni da 2-3 ore ciascuna svolte in modalità interattiva in presenza
- Durante le lezioni il docente promuoverà la partecipazione attiva degli studenti attraverso domande, discussioni guidate, analisi di casi studio e momenti di riflessione condivisa

- Le lezioni integreranno contenuti teorici con esempi pratici e applicazioni concrete

### **Laboratori pratici**

- 6 laboratori da 3 ore ciascuno (oppure 9 da 2 ore) svolti in presenza con modalità interattiva
- Attività hands-on per l'applicazione pratica dei concetti teorici
- Lavoro individuale e di gruppo sotto la supervisione del docente

### **Contenuti asincroni**

- Una quota massima del 10% del corso verrà erogata in modalità asincrona mediante video-registrazioni
- I contenuti asincroni integrano le lezioni frontali
- Gli studenti potranno accedere a questi contenuti secondo i propri tempi di studio per consolidare e ampliare gli argomenti trattati in aula

## **Lingua di erogazione**

Il corso verrà interamente erogato in **lingua inglese**

### **Materiale didattico**

Dispense e slide del corso fornite dai docenti.

Si segnalano i seguenti testi per approfondimento:

- The basics of cloud computing ISBN-13: 978-0124059320 Autori: Derrick Rountree, Ileana Castrillo
- Designing Data-Intensive Applications: The Big Ideas Behind Reliable, Scalable, and Maintainable Systems ISBN-13: 978-1449373320 Autore: Martin Kleppmann

### **Periodo di erogazione dell'insegnamento**

Secondo anno, primo semestre

### **Modalità di verifica del profitto e valutazione**

La valutazione dell'apprendimento si articola in **due componenti complementari**, entrambe obbligatorie:

### **Prova scritta (25 punti)**

La prova scritta valuta la conoscenza degli argomenti trattati durante il corso attraverso:

- **12-13 domande a scelta multipla** per verificare la comprensione dei concetti fondamentali
- **2-3 domande a risposta aperta** per valutare la capacità di analisi e sintesi

**Durata:** 60-75 minuti

**Punteggio massimo:** 25 punti

## **Prova orale - Presentazione di approfondimento (7 punti)**

La prova orale consiste nella presentazione e discussione di un tema di approfondimento scelto tra:

- Argomenti correlati al corso ma non trattati durante le lezioni
- Approfondimenti di tematiche già affrontate in aula

### **Modalità di svolgimento:**

- **Preparazione:** il lavoro di ricerca e la creazione delle slide possono essere realizzati in gruppi di 2 persone
- **Presentazione e valutazione:** individuali e personalizzate per ciascun componente del gruppo
- **Approvazione del tema:** l'argomento deve essere previamente concordato con il docente

**Punteggio massimo:** 7 punti

## **Criteri di superamento dell'esame**

L'esame si considera **superato** quando si verificano **entrambe** le seguenti condizioni:

1. **Soglia minima per ciascuna prova:** punteggio ? 15 per la prova scritta e ? 4 in quella orale
2. **Punteggio complessivo:** somma dei punteggi delle due prove ? 18 punti

**Voto finale:** corrisponde alla somma dei punteggi delle due prove (massimo 32 punti, corrispondente a 30 e lode).

## **Note importanti**

- **Non sono previste prove parziali** durante lo svolgimento del corso
- Il mancato raggiungimento della soglia minima in una delle due prove comporta la ripetizione della specifica prova e non dell'intero esame

## **Orario di ricevimento**

Martedì 12:30-14:30, chiedere conferma per email

## **Sustainable Development Goals**

IMPRESE, INNOVAZIONE E INFRASTRUTTURE

---