

## COURSE SYLLABUS

### Introduction To Bioinformatics

2223-3-E3101Q116

---

#### Obiettivi

Alla fine del corso lo studente avrà compreso le principali problematiche computazionali e tecniche algoritmiche in bioinformatica. Sarà in grado di scrivere programmi Python di modeste dimensioni per risolvere problemi in bioinformatica utilizzando anche dati presenti su basi di dati pubbliche

#### Conoscenza e comprensione

Questo insegnamento fornisce le conoscenze basilari e capacità di comprensione relativamente a:

- Algoritmi su sequenze biologiche.
- Strutture dati per l'indicizzazione di sequenze
- Algoritmi per la ricostruzione di storie evolutive
- Shell di Unix
- Programmazione in Python in campo bioinformatico
- Formati di file usati in bioinformatica

#### Capacità di applicare conoscenza e comprensione

Alla fine dell'insegnamento gli studenti saranno in grado di:

- Comprendere quali algoritmi e strutture dati utilizzare per affrontare alcuni problemi in bioinformatica
- Scrivere programmi in Python in campo bioinformatico
- Costruire semplici pipeline che integrano Python e la shell Unix

#### Contenuti sintetici

Principali problemi e algoritmi in bioinformatica. Pattern Matching. Allineamento di sequenze. Sequenziamento di

DNA. Storie evolutive. Gestione di dati e basi di dati biologici.

## Programma esteso

1. Algoritmi e strutture dati per il pattern matching. Algoritmi di Karp-Rabin, Dömölki.
2. Suffix tree e suffix array: gestione, pattern matching e loro utilizzo per la ricerca della sottostringa più lunga.
3. Allineamento di due sequenze. Allineamento globale, locale, con banda. Costi di gap lineare e generico. Allineamento multiplo.
4. Sequenziamento di DNA. Grafi di overlap e grafi di de Bruijn.
5. Alberi evolutivi. Modelli a partire da caratteri: algoritmo di Gusfield per la filogenesi perfetta. Modelli a partire da distanze: distanze ultrametriche e distanze additive. Algoritmi UPGMA e Neighbor Joining. Cenni di ricostruzione tramite massima verosimiglianza
6. Genotipi e Aplotipi. Distinzione fra singolo individuo e pedigree.
7. Formati di file di dati biologici
8. Metodologie di sviluppo software open source per la bioinformatica
9. Cenni di shell
10. Python.
11. Pandas.
12. Biopython

## Prerequisiti

Algoritmi e strutture dati; Linguaggi di programmazione;

## Modalità didattica

Lezioni in aula e attività di laboratorio. Utilizzo della piattaforma di e-learning per integrare lo studio individuale tramite arricchimento delle attività in aula e per autovalutazioni in itinere del livello di preparazione ottenuto.

Il corso è erogato in Italiano.

## Materiale didattico

Il libro di testo seguito per quasi tutte le lezioni è "Algorithms on Strings, Trees and Sequences", di Daniel Gusfield, Cambridge Univ. Press. La biblioteca tiene alcune copie del libro di testo, anche come [ebook](#).

Il libro "An Introduction to Bioinformatics Algorithms" di N. Jones, P. Pevzner viene usato esclusivamente come approfondimento per la parte di ricostruzione di filogenesi e di sequenziamento.

Il libro "[Theoretical Evolutionary Genetics](#)" di J. Felsenstein viene usato esclusivamente come approfondimento per la parte di ricostruzione di filogenesi. Un libro analogo è [Population and Quantitative Genetics](#) by Graham Coop.

Per quanto riguarda Python fare riferimento a [Pensare in Python](#) di A. B. Downey (versione inglese [Think Python](#)).

Per la parte relativa a Pandas il libro di riferimento è [Python Data Science Handbook](#) di VanderPlas

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

primo semestre

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

La verifica dell'apprendimento consiste di una prova scritta e di una parte progettuale.

La prova scritta è individuale, basata su domande a risposta aperte relativa alle nozioni presentate nel corso relative ai contenuti di natura algoritmica. La prova scritta dura un'ora e contiene 4 domande, ma bisogna rispondere solo a 3 delle 4 domande.

La parte progettuale consiste nella scrittura di un programma in Python e viene svolta individualmente o in piccoli gruppi (max 3 persone), con successiva presentazione del lavoro fatto. I gruppi sono formati autonomamente dagli studenti. Il testo del progetto è lo stesso per tutti gli studenti ed è valido per una sessione.

La discussione del progetto avviene dopo avere superato la prova scritta ed entro un anno da tale superamento.

La valutazione finale viene ottenuta tramite media pesata delle votazioni ottenute nelle due parti, con peso 50% per la prova scritta e 50% per il progetto, ma entrambe le parti devono avere valutazione positiva.

Non sono previste prove in itinere.

## **Orario di ricevimento**

Il ricevimento è online e su appuntamento: <https://www.unimib.it/gianluca-della-vedova>

## **Sustainable Development Goals**

---