

VALENTINA PACCHIARELLI | valentina.pacchiarelli@gmail.com | GAETANO COLETTA - Enea | gaetano.coletta@enea.it |
ROSSANA COTRONEO - Enea | rossana.cotroneo@enea.it | ALESSANDRO ZINI - Enea | alessandro.zini@enea.it

INTRODUZIONE

L'intelligenza artificiale consente di simulare i processi dell'intelligenza umana attraverso la creazione e l'applicazione di algoritmi integrati in un ambiente di calcolo dinamico. La loro capacità di catturare relazioni anche non lineari potenzialmente molto complesse favorisce un buon adattamento ai dati. Per questo lavoro, sono stati utilizzati dei modelli di intelligenza artificiale per predire e integrare le mancate risposte parziali relative alla Rilevazione statistica sulle imprese nel campo delle biotecnologie consuntivo 2021 e proiezioni sul 2022 svolta dall'ENEA in collaborazione con Assobiotec e, successivamente, si procederà con le previsioni statistiche in avanti. L'analisi e l'elaborazione dei dati è stata effettuata tramite il software di programmazione visiva per l'analisi dei dati "Orange- data mining", il quale utilizza Python come linguaggio di programmazione.

OBIETTIVO

Stimare i dati mancanti per il dato del 2021, nonché la previsione per il dato del 2022, relativamente ad alcune delle variabili-chiave Rilevazione statistica sulle imprese nel campo delle biotecnologie consuntivo 2021 e proiezioni sul 2022 svolta dall'ENEA in collaborazione con Assobiotec

METODOLOGIA

Le variabili per le quali è stata effettuata la stima dei valori mancanti e poi la previsione sono: fatturato, spese per Ricerca e Sviluppo, spese per Ricerca e Sviluppo nel comparto biotech, numero degli addetti totali, numero degli addetti per Ricerca e Sviluppo quelli relativi al comparto biotech. Allo scopo è stata utilizzata la serie storica pregressa (2014-2022). Dopo aver svolto il processo di controllo e correzione dei dati sono stati testati due modelli di intelligenza artificiale, le Reti Neurali (NN) e il Gradient Boosting (GB). A corredo dell'applicazione dei modelli vengono presentate misure di accuratezza e precisione degli stessi.

Pre-processamento dati

Pulizia e correzione dei dati
Creazioni di sottoinsiemi di aziende in base al ciclo di vita dell'azienda stessa

Elaborazione dati



Creazione workflow per singola variabile e in base al ciclo di vita dell'azienda
Scelta dei modelli da utilizzare (NN e GB)

Trasformazione dati

Trovare la combinazione di input da inserire nei modelli per ottenere i risultati più efficienti e accurati possibili attraverso l'analisi del Test and Score

Validazione dati

Predire i dati del 2021 sia con NN che GB e, con i valori calcolati, predire i dati del 2022.
Confronto dei dati ottenuti con quelli già calcolati dalla Rilevazione per verificarne l'accuratezza



RISULTATI & CONCLUSIONI

Alla luce delle metriche maggiormente in uso, entrambi i modelli paiono in grado di fornire previsioni attendibili, con un soddisfacente livello di minimizzazione dell'errore in predizione. Tra i due, il modello GB sembra esprimere una maggiore bontà di adattamento ai dati, calcolato in termini di R² ed errore quadratico medio, e stime più accurate e precise.

NN	FATTURATO		CORRELAZIONE	R ²	RS INTRA BIOTECH		CORRELAZIONE	R ²	ADDETTI RS		CORRELAZIONE	R ²
	2021 CON NN		1,0000	1,0000	2021 CON NN		0,9993	0,9985	2021 CON NN		0,9999	0,9999
	2022 CON NN		0,9986	1,0000	2022 CON NN		0,9909	0,9970	2022 CON NN		0,9992	0,9998
	2021 CON GB		1,0000	1,0000	2021 CON GB		1,0000	0,9999	2021 CON GB		1,0000	1,0000
	2022 CON GB		0,9986	0,9971	2022 CON GB		0,9911	0,9824	2022 CON GB		0,9993	0,9985
GB	SPESA RS		CORRELAZIONE	R ²	ADDETTI TOTALI		CORRELAZIONE	R ²	ADDETTI RS BIOTECH		CORRELAZIONE	R ²
	2021 CON NN		0,9512	0,9048	2021 CON NN		1,0000	1,0000	2021 CON NN		0,9996	0,9991
	2022 CON NN		0,9390	0,8188	2022 CON NN		0,9990	0,9999	2022 CON NN		0,9943	0,9983
	2021 CON GB		0,9980	0,9961	2021 CON GB		1,0000	1,0000	2021 CON GB		0,9995	0,9990
	2022 CON GB		0,9396	0,8829	2022 CON GB		0,9990	0,9980	2022 CON GB		0,9944	0,9887
GB	RS INTRA		CORRELAZIONE	R ²	ADDETTI BIOTECH		CORRELAZIONE	R ²				
	2021 CON NN		0,9998	0,9995	2021 CON NN		0,9987	0,9973				
	2022 CON NN		0,9991	0,9991	2022 CON NN		0,7523	0,9947				
	2021 CON GB		1,0000	1,0000	2021 CON GB		1,0000	0,9999				
	2022 CON GB		0,9991	0,9982	2022 CON GB		0,7523	0,5660				