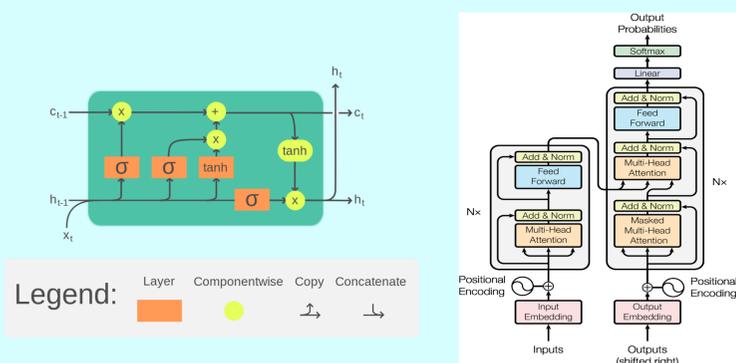


Rafforzare le previsioni delle serie storiche nelle Statistiche Ufficiali mediante i transformers

ALBERICO EMANUELE – Università «La Sapienza» emanuele.1799376@studenti.uniroma1.it | FRANCESCO PUGLIESE - Istat frpuglie@istat.it | MASSIMO DE CUBELLIS - Istat decubellis@istat.it | ANGELA PAPPAGALLO - Istat pappagallo@istat.it

Introduzione

Negli ultimi anni, i rapidi progressi della tecnologia dell'informazione hanno significativamente portato ad avanzamenti nel settore dell'intelligenza artificiale (IA), specialmente nei rami del Machine Learning (ML) e il Deep Learning (DL). Queste innovazioni sono state applicate anche nelle Statistiche Ufficiali. Nella previsione delle Serie Storiche, oltre ai metodi statistici tradizionali come **ARIMA**, i modelli di Rete Neurali Profonde (Deep Neural Networks) come **LSTM** o **GRU** hanno mostrato risultati entusiasmanti. I modelli Transformer, inizialmente sviluppati per il Natural Language Processing (NLP), vengono ora utilizzati per l'analisi delle serie temporali, eliminando la necessità di architetture ricorrenti e basandosi su meccanismi di attenzione per catturare le relazioni contestuali. Questo studio analizza l'applicazione dei **Transformer** alla previsione delle serie temporali di indicatori socio-economici rilevanti in **Istat**, confrontando i risultati con quelli ottenuti tramite **ARIMA**, **LSTM** e **GRU**.



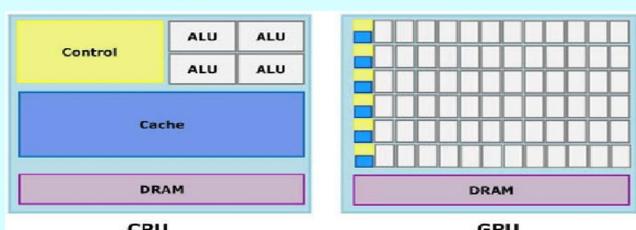
Dati ed Elaborazione

L'esperimento ha analizzato quattro serie temporali socio-economiche raccolte da Istat. Il **Prodotto Interno Lordo (PIL)**, il **Tasso di Disoccupazione**, l'**Inflazione** e infine l'**Indice di Fiducia dei Consumatori**. I dati del PIL coprono il periodo dal 1 marzo 1990 al 1 marzo 2023, su base trimestrale. I dati sulla disoccupazione vanno dal 1 marzo 2004 al 1 marzo 2023, su base trimestrale. I dati sull'inflazione vanno dal 1 gennaio 1997 al 1 giugno 2023, su base mensile. I dati dell'Indice di Fiducia dei Consumatori vanno dal 1 gennaio 1998 al 1 maggio 2023, su base mensile. Prima di inserire i dati nel **Transformer**, è stata effettuata una fase di **pre-elaborazione**. Questa ha comportato l'analisi dei dati, inclusa la pulizia, la trasformazione e la preparazione dei dati grezzi per renderli adatti all'analisi o all'uso in modelli e algoritmi di machine learning. Le tecniche di pre-elaborazione utilizzate per i dati disponibili consistono essenzialmente in tre passaggi: l'**interpolazione** per convertire le serie trimestrali in **serie mensili** per aumentare la dimensione del **campione**, la normalizzazione dei dati e una trasformazione finale delle serie da serie storica (time series) a **Training Set** supervisionato.

Metodologia

Il lavoro mira a dimostrare l'efficacia dei modelli **Transformer** per la previsione delle serie temporali attraverso un'analisi comparativa con metodi tradizionali come **LSTM**, **GRU** e **PROPHET**.

- Le reti **LSTM (Long Short-Term Memory)** [1] sono una tipologia di Reti Neurali Ricorrenti (RNN) progettate per catturare **dipendenze a lungo termine**.
- Le **GRU (Gated Recurrent Unit)** [2] sono una semplificazione delle LSTM. Sebbene le GRU abbiano meno parametri e siano più efficienti, offrono prestazioni simili alle LSTM, con la scelta tra i due modelli che dipende dalla quantità di dati disponibili.
- **PROPHET**, sviluppato da **Facebook (Meta)** nel 2017 [3], è un modello di previsione delle serie temporali progettato per gestire caratteristiche economiche comuni.
- I **Transformer**, introdotti da **Google** nel 2017 [4], sono reti neurali che elaborano sequenze di dati utilizzando il **meccanismo d'attenzione** automatica anziché le funzioni **ricorrenti**. La loro architettura **encoder-decoder** è stata applicata con successo in vari compiti di elaborazione del linguaggio naturale. La funzione di **attenzione** permette di dare più peso alle parti rilevanti della sequenza di input, migliorando l'elaborazione delle informazioni. I Transformer offrono vantaggi rispetto ai metodi tradizionali di previsione delle serie storiche, grazie alla loro capacità di catturare efficacemente dipendenze a lungo termine e gestire informazioni in parallelo, quindi sono più veloci su **GPUs** (Graphics Processing Units) e **TPUs** (Tensor Processing Units).



Risultati

La performance dei modelli è stata valutata utilizzando le metriche **Root Mean Square Error (RMSE)**, **Mean Absolute Error (MAE)** e **R2 (Coefficiente di Determinazione)**. L'**RMSE** è una misura della dispersione tra i valori osservati e i valori previsti da un modello. Il **MAE** calcola la media delle differenze assolute tra i valori previsti e quelli osservati. L'**R2** è una misura di quanto bene un modello di regressione si adatta ai dati.

PIL

Modello	RMSE	MAE	R ²
PROPHET	15899.177213	9208.549353	-0.002825
GRU	11207.663313	7490.357206	0.774993
LSTM	10492.326076	6611.401239	0.802798
Transformer	4080.375917	2296.781796	0.970176

Le metriche indicano che tutti i modelli funzionano ragionevolmente bene sui dataset, con l'**architettura Transformer** che ottiene le migliori prestazioni,

mentre **LSTM** ha una performance paragonabile a quella di **GRU**. Tuttavia, il modello **PROPHET** ha una scarsa performance sui dati di test, poiché i suoi errori superano quelli generati dalla media. Questi risultati suggeriscono che il meccanismo di attenzione, insieme all'introduzione della codifica temporale, offre vantaggi significativi rispetto ai metodi standard, come la ricorrenza.

Tasso di Disoccupazione

Modello	RMSE	MAE	R ²
PROPHET	0.300425	0.224288	0.073818
GRU	0.262894	0.195661	0.906261
LSTM	0.263004	0.197782	0.906182
Transformer	0.210502	0.143567	0.939901

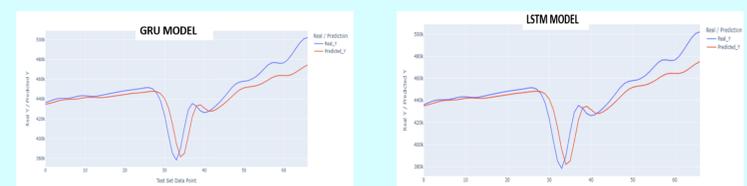
Inflazione

Modello	RMSE	MAE	R ²
PROPHET	1.931924	0.809225	-0.000028
GRU	1.308849	0.635804	0.880049
LSTM	1.331893	0.655166	0.875788
Transformer	1.222542	0.594689	0.895347

Indice di Fiducia dei Consumatori

Modello	RMSE	MAE	R ²
PROPHET	4.624641	3.562541	-0.00132
GRU	3.760103	2.873503	0.746601
LSTM	3.766522	2.868066	0.745735
Transformer	3.616185	2.705487	0.765627

Di seguito è importante notare il confronto tra diversi modelli durante sul **dataset di test** riguardante il **PIL** che include il periodo della pandemia di **Covid-19**, identificabile nella depressione mostrata dalla curva nella figura. Nonostante sia un evento imprevedibile e anomalo, il modello **Transformer** riesce a catturare la tendenza della curva meglio delle due reti neurali, soprattutto nel periodo successivo alla pandemia, seppur con un leggero ritardo.



Conclusioni

Questo studio ha esplorato l'uso dell'architettura **Transformer** per la previsione di serie storiche, confrontandola con i modelli **PROPHET**, **GRU** e **LSTM**. I Transformer hanno superato i metodi tradizionali in tutti gli esperimenti, mostrando particolare efficacia con dati ad alta dimensionalità. I migliori risultati sono stati ottenuti sui dati del **PIL**, che avevano il maggior numero di osservazioni.

Bibliografia

- [1] Hochreiter, Sepp, and Jürgen Schmidhuber. "Long short-term memory." Neural computation 9.8 (1997): 1735-1780.
- [2] Dey, R., & Salem, F. M. (2017, August). Gate-variants of gated recurrent unit (GRU) neural networks. In 2017 IEEE 60th international midwest symposium on circuits and systems (MWSCAS) (pp. 1597-1600). IEEE.
- [3] Jha, B. K., & Pande, S. (2021, April). Time series forecasting model for supermarket sales using FB-prophet. In 2021 5th International Conference on Computing Methodologies and Communication (ICCMC) (pp. 547-554). IEEE.
- [4] Wen, Q., Zhou, T., Zhang, C., Chen, W., Ma, Z., Yan, J., & Sun, L. (2022). Transformers in time series: A survey. arXiv preprint arXiv:2202.07125.