

Apprendimento di reti neurali ricorrenti con autoencoder con applicazione sulla modellazione del pancreas artificiale

Un problema delle reti neurali ricorrenti (RNN) nell'identificazione di sistemi dinamici¹, come le Long Short-Term Memory (LSTM)² o le Gated Recurrent Unit (GRU)³, risiede nella loro inizializzazione dello stato, in quanto esse stesse sistemi dinamici. Solitamente il loro stato è inizializzato a vettori di zero.

Questo non crea solo possibili problemi nelle predizioni, dove bisogna aspettare un transitorio per far convergere la predizione della rete a quella del sistema, ma non permette un utilizzo efficace dei dati in training. Per esempio, se una sequenza di training è composta da 1000 step e le dinamiche del sistema sono osservabili in una decina o centinaio di step, il transitorio iniziale non permette un efficace possibile training in sottosequenze, che sarebbe parallelizzabile e migliorativo per la generalizzazione tramite stochastic gradient descent.

Varie alternative di inizializzazione dello stato di questi modelli sono state proposte negli anni, tuttavia una recente proposta di Masti e Bemporad⁴, sfrutta degli autoencoder, ovvero ulteriori reti neurali feedforward, per inizializzare lo stato della rete partendo dai dati di una finestra temporale precedente del contesto, ovvero input e output.

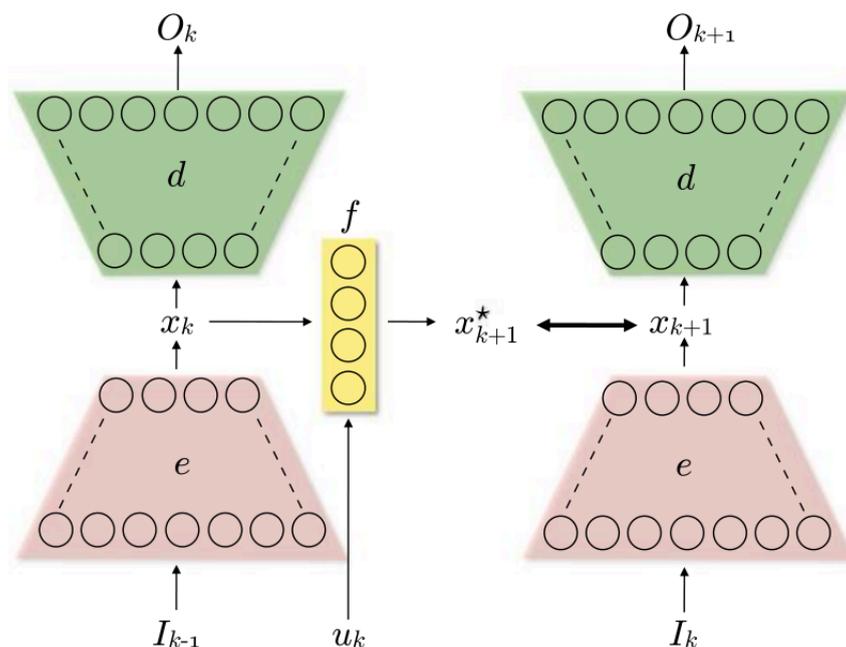


Figura da Masti and Bemporad, 2021, "[Learning nonlinear state-space models using autoencoders](#)".
Rappresentazione schematica della struttura proposta, dove f rappresenta la rete neurale ricorrente (o un modello non lineare generico) e e e d rappresentano gli autoencoder addestrati.

¹ Ljung et al., 2020, "[Deep Learning and System Identification](#)"

² Hochreiter and Schmidhuber, 1997, "[Long Short-Term Memory](#)"

³ Cho et al., 2014, "[Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation](#)"

⁴ Masti and Bemporad, 2021, "[Learning nonlinear state-space models using autoencoders](#)"

Gli autoencoder e le reti neurali vengono addestrati insieme con una singola funzione di costo, permettendo così la cosiddetta truncated backpropagation through time (TBPTT), permettendo la parallelizzazione citata precedentemente.

Questa metodologia potrebbe beneficiare l'identificazione delle dinamiche nella relazione insulina-glucosio nel contesto del pancreas artificiale.

Il pancreas artificiale è un dispositivo medico in fase di sviluppo volto a migliorare la gestione del diabete mellito di tipo 1 (T1D). Il T1D è una malattia autoimmune cronica in cui il pancreas smette di produrre insulina, un ormone fondamentale per regolare l'utilizzo del glucosio da parte delle cellule. Questo porta a livelli elevati di glucosio nel sangue (iperglicemia). Il pancreas artificiale mira a emulare la funzione del pancreas sano, utilizzando sensori per monitorare continuamente il glucosio (CGM) e microinfusori per somministrare insulina. Un algoritmo di controllo all'interno del sistema calcola la quantità di insulina necessaria in base alle misurazioni del glucosio.

In questo scenario, l'identificazione accurata delle dinamiche insulina-glucosio è cruciale per il corretto funzionamento del pancreas artificiale, ma lo stato iniziale del sistema (ovvero i livelli di glucosio e insulina al momento dell'avvio del sistema o in un determinato istante) non è sempre noto a priori. Inoltre, le dinamiche in questione possono manifestarsi su scale temporali più brevi rispetto alla durata totale delle registrazioni dei dati, che spesso coprono diversi giorni. Pertanto, la capacità di inizializzare efficacemente lo stato delle reti neurali ricorrenti, come proposto dalla metodologia basata sugli autoencoder, si rivela particolarmente promettente per migliorare l'identificazione di queste dinamiche e, di conseguenza, le prestazioni del pancreas artificiale, oltre a beneficiare di una fase di training maggiormente efficace.

Obiettivo della tesi

Questa tesi si pone come obiettivo l'utilizzo del framework proposto da Masti e Bemporad per l'identificazione del sistema pancreas artificiale. Gli obiettivi chiave sono:

1. **Implementare il framework teorico:** riprodurre i risultati ottenuti da Masti e Bemporad.
2. **Valutare le prestazioni:** confrontare le performance del modello con autoencoder rispetto a modelli senza (accuratezza, velocità di convergenza, robustezza in presenza di rumore, ...).
3. **Applicazione sul pancreas artificiale:** valutare l'impatto di questa metodologia in particolare sul sistema pancreas.

L'implementazione sarà principalmente in MATLAB in quanto il pancreas artificiale è gestito in questo framework.

Ci si concentrerà su architetture LSTM e GRU per le RNN, con modelli feedforward per gli autoencoder.

Il modello ottenuto potrà essere validato su toy systems prima dell'implementazione vera e propria sul pancreas artificiale.