Spunti di tesi e stage

Alcuni di questi spunti si basano sugli Spiking Neural P Systems (SNPS), un modello introdotto nel paper [4], che contiene una panoramica generale del suo funzionamento; mentre altri riguardano le Spiking Neural Networks (SNN), di cui in [3] è presente una review recente. Per una descrizione più chiara e concisa, che comprende SNPS, SNN e alcune delle possibili applicazioni, vedere [17].

È stato sviluppato un simulatore in grado di eseguire SNPS con anti-spike e white hole (vedi [11]). In questo **link** è presente una versione pronta all'uso, con il paper che ne descrive il funzionamento. Alcuni spunti si riferiscono direttamente a questo simulatore.

In linea generale, una direzione di ricerca trasversale e sempre valida per ciascuna delle proposte presentate consiste nella valutazione dei modelli su dataset differenti, sia in termini di dominio sia di tipologia di dato (es. segnali temporali, dati tabellari o sequenze). Sebbene il formato immagine rimanga il più indicato e naturale per l'architettura sviluppata finora, l'adattamento a strutture dati diverse rappresenta un'ottima opportunità di sperimentazione.

Per un approccio pratico a come lavorare su una rete SNN che analizzi le immagini, si trova un tutorial esaustivo **qui**.

1 Ispirazione biologica

Tesi magistrale, SNPS o SNN

Il cervello umano rappresenta un sistema di elaborazione estremamente efficiente, in grado di eseguire in parallelo un'enorme quantità di operazioni con un consumo energetico molto ridotto rispetto ai sistemi computazionali tradizionali. Pur non essendo ottimale in termini di velocità o precisione numerica, eccelle in compiti complessi grazie alla natura fortemente distribuita e adattiva delle sue reti neurali.

Tuttavia, la maggior parte della letteratura scientifica e dei trattati fondamentali di neuroscienze descrive le vie sensoriali e anatomiche prevalentemente da una prospettiva medica e clinica. Esiste quindi uno spazio di ricerca nella traduzione formale di questi processi biologici (es. la via visiva, la retina o la corteccia visiva primaria [6]) in algoritmi di feature extraction e di rielaborazione del segnale.

L'obiettivo di questa proposta è sviluppare un modello di ispirazione biologica nel framework SNPS o SNN, concepito come una rete spiking indipendente

e non collegata al simulatore sviluppato.

Sebbene il punto di partenza si focalizzi sul dominio visivo, i meccanismi individuati possono essere estesi e applicati ad altre tipologie di dati analizzabili da reti spiking, come segnali audio, flussi video, sequenze temporali o testo.

Tali studi richiedono una comprensione dei principi neurofisiologici coinvolti e la disponibilità ad approfondire la letteratura neuroscientifica, si consiglia il manuale *Principles of Neural Science* di Kandel et al. Un lavoro esaustivo che comprende SNN e ispirazione al cervello è [18].

Un lavoro simile è stato eseguito da M. Balzerani, che ha prodotto un documento (*Towards Realism*) che racchiude alcuni dei molti meccanismi da studiare. Questa raccolta di informazioni è stata poi usata per modellare parte del simulatore presentato.

1.1 Estensione topologica con Self Organizing Maps

Per avvicinare i modelli spiking ad architetture neuro-anatomiche reali, un'estensione naturale consiste nell'introdurre una dimensione fisica e posizionale ai neuroni. Attualmente, nei simulatori SNPS i neuroni sono gestiti come elenchi astratti di nodi privi di coordinate. Assegnando a ciascun neurone una posizione nello spazio 2D (o 3D), la topologia della rete smette di essere un semplice grafo privo di forma e assume una vera e propria geometria spaziale, capace di rispecchiare strutture biologiche o porzioni di tessuto cerebrale.

In questo contesto, la connettività sinaptica e la forza dei collegamenti possono essere modellate in funzione della distanza fisica tra i nodi. Inserendo regole dinamiche di movimento o di plasticità strutturale (creazione, allungamento o distruzione di sinapsi in base all'attività di firing), si può dare alla rete una capacità di auto-organizzazione non supervisionata, integrando i principi delle Self-Organizing Maps [7]. Questo principio è stato recentemente applicato alle SNN, nel lavoro [19].

2 Explainability di Frequency Chaos Game Representation

Tesi triennale, estendibile a magistrale con 2.1, SNPS

L'applicazione di modelli spiking alla classificazione di dati genomici rappresenta un ambito di ricerca di forte interesse. Nel lavoro condotto da A. Ruggiero, disponibile in questo **link**, è stato testato il simulatore SNPS nella classificazione di genomi batterici (afferenti ai generi *Aeromonas*, *Citrobacter*, *Helicobacter* e *Streptococcus*). Tali genomi sono stati convertiti in immagini mediante la *Frequency Chaos Game Representation* (FCGR) [5]. Il modello ha mostrato prestazioni performanti, tuttavia ad oggi manca un'analisi sistematica di spiegabilità (Explainable AI) sul funzionamento interno di tale modello applicato a matrici FCGR.

Per avere un'idea della direzione di ricerca, un'analisi affine è stata condotta da M. Ventura, il quale ha prodotto un report di XAI focalizzato sugli SNPS

ma applicato a un dataset differente.

L'obiettivo di questa tesi è condurre uno studio approfondito di spiegabilità sulla rete SNPS per FCGR, volto a:

- Identificare quali kernel convoluzionali, sinapsi e regole di firing stiano effettivamente contribuendo al successo della classificazione;
- Interpretare il ruolo dei singoli pixel delle FCGR (corrispondenti alle frequenze dei k-meri nel genoma) per comprendere quali regioni e frequenze nucleotidiche abbiano reale rilevanza biologica nella distinzione delle classi;
- Formalizzare metriche e tecniche di visualizzazione per la trasparenza decisionale del modello spiking [9].

2.1 Ottimizzazione per FCGR generica

Una volta delineata la trasparenza decisionale e la dinamica interna della rete attraverso l'analisi di spiegabilità, il lavoro può evolvere verso la fase di potenziamento strutturale ed estensione applicativa del sistema. La padronanza dei meccanismi di firing e della selezione delle feature su matrici FCGR consente di superare i vincoli dell'architettura originaria, introducendo una maggiore complessità computazionale e una superiore capacità di generalizzazione.

L'obiettivo di questa fase è trasformare la rete da un modello ottimizzato su un caso di studio ristretto (limitato alle 4 classi di generi batterici considerate nella sperimentazione iniziale) a un framework flessibile e altamente adattabile a diverse tipologie di dati genomici espressi in formato FCGR.

Le principali direzioni di sviluppo includono:

- Estensione del benchmark a un numero maggiore di classi e test su problemi di classificazione con dimensioni dei genomi più omogenee, incrementando il livello di sfida per la rete;
- Introduzione di ulteriori layer di elaborazione, meccanismi di convoluzione/pooling in parallelo e regole di firing avanzate;
- Adattamento dinamico dei parametri di rete (come la risoluzione delle immagini FCGR o i range di quantizzazione) per garantire elevate prestazioni anche in presenza di variazioni strutturali nei dati in ingresso.

3 Confronto di rappresentazioni genomiche

Tesi triennale o magistrale, SNPS

L'elaborazione di dati genomici mediante Spiking Neural P Systems (SNPS) è una direzione interessante, come descritto nella proposta precedente. La FCGR rappresenta tuttavia solo una delle possibili strategie per trasformare una sequenza di DNA (composta dalle basi $\{A, C, G, T\}$) in un'immagine bidimensionale. In letteratura esistono infatti diverse altre metodologie volte a

convertire sequenze biologiche in rappresentazioni visive. Qui riportate alcune di queste tecniche:

- **FCGR:** Utilizzata come termine di confronto principale, valutandone il comportamento e la risposta della rete in analogia con quanto svolto nei lavori preliminari sopracitati;
- **DNA walk:** Mappatura basata sul lavoro di Akbari et al. [1], che ne propone una classificazione con CNN. Si converte la sequenza nucleotidica in un cammino bidimensionale compatto, trasformando le traiettorie delle basi in immagini strutturate per ciascuna specie;
- **Hilbert curve mapping:** Disposizione della sequenza lungo una curva di Hilbert 2D [2], una tecnica utilizzata in genomica per preservare la località spaziale dei nucleotidi all'interno della matrice dell'immagine. Anche qui è presente un lavoro che sfrutta le CNN [16].

Questi non sono che un esempio, lo studente è libero di cercare e implementare altri metodi, per esempio usando i Recurrence Plot [15]. L'obiettivo di questa proposta è valutare come differenti tecniche di conversione da sequenza a immagine influenzino la capacità di estrazione delle feature e l'accuratezza di classificazione della rete SNPS.

Anche in questa proposta, il passo successivo sarebbe quello di migliorare la rete e adattarla ad ogni tipo di rappresentazione analizzata. C'è la possibilità di unire un lavoro di explainability per analizzare come il modello si adatta alle diverse rappresentazioni.

4 Confronto tra SNPS, CNN e SNN

Tesi magistrale, SNPS, SNN e ANN

L'architettura SNPS sviluppata per la classificazione di immagini disponibile al **link** nasce adattando i principi di una rete neurale convoluzionale (CNN) all'interno del formalismo spiking a membrane.

Questa proposta di tesi punta a creare una rete CNN che rispecchia la struttura dell'SNPS, e una Spiking Neural Network equivalente, ottenendo così tre modelli strutturalmente speculari ma basati su tre paradigmi computazionali distinti:

1. **SNPS:** Sistema spiking discreto e sincrono a membrane, con regole di firing e quantizzazione. L'ottimizzazione attualmente avviene mediante classificatori lineari/SVM applicati ai vettori di spike estratti dai layer intermedi;
2. **CNN:** Rete convoluzionale artificiale classica a pesi reali, il tuning avviene con la discesa lungo il gradiente standard (*Backpropagation*) su pesi reali;

3. **SNN:** Rete spiking neuromorfica basata su potenziali di membrana dinamici ed eventi temporali, con ottimizzazione tramite algoritmi dedicati all'elaborazione temporale, quali la *Backpropagation Through Time* o la *Spike-timing-dependent plasticity*.

Un aspetto di grande interesse teorico e applicativo risiede nel confronto tra le diverse metodologie di addestramento delle reti, che variano radicalmente tra i tre modelli. La scelta del dato non è vincolata, purchè resti invariato tra le tre reti. Dopo la definizione dei modelli, in una seconda fase più corposa, il progetto prevede il ridimensionamento delle tre reti verso architetture di maggior complessità e profondità, analizzando come ciascun metodo di training risponda all'aumento delle dimensioni del modello e dei dati.

4.1 Estensione per serie temporali per water stress classification

Come estensione del confronto architetturale tra modelli si propone di applicare le tre metodologie all'analisi di serie temporali, prendendo come riferimento il lavoro recente di Orellana-Martín et al. *Towards olive tree water stress classification with spiking neural P systems*.

Il paper affronta il problema dell'individuazione dello stress idrico negli olivi a partire da dati temporali raccolti da sensori (es. crescita dei frutti e dinamiche fogliari). Mentre il modello sviluppato finora per la classificazione di immagini opera su input statici o spaziali, questa tesi esplora l'elaborazione di sequenze dinamiche confrontando le seguenti strategie:

1. **SNPS Reservoir Computing:** Adattamento del modello SNPS come *reservoir* dinamico ricorrente a regole non lineari (NSNP) [8], in cui la topologia della rete rimane fissa e viene addestrato unicamente il layer di readout finale;

2. **Recurrent SNN:** Implementazione di una SNN ricorrente addestrata su sequenze temporali;

3. **CNN 1D o RNN:** Architettura di reti neurali artificiali (es. CNN 1D o LSTM) a pesi reali per l'analisi delle medesime serie temporali.

L'obiettivo è valutare come i tre approcci catturino le dipendenze temporali dei dati sensoriali e confrontarne le caratteristiche come la complessità di training e il memory footprint.

5 Calcolo e minimizzazione dei costi energetici

Tesi triennale o magistrale, SNPS o SNN

Un aspetto centrale nell'adozione dei modelli spiking è l'efficienza energetica rispetto alle reti neurali tradizionali (ANN). Tuttavia, ad oggi non esiste un

framework consolidato e unico per il calcolo e la stima del consumo energetico negli SNPS e SNN.

Per analizzare e confrontare i consumi, un metodo ampiamente riconosciuto consiste nel conteggio delle operazioni elementari ed energeticamente onerose:

- **ANN (MAC / FLOPs):** Le reti tradizionali basano il loro costo sulle operazioni di *Multiply-Accumulate*, che richiedono moltiplicazioni tra numeri reali *(Floating Point Operations)* con un elevato consumo di energia per operazione;
- **SNN e SNPS (SOPs / AC)**: L'elaborazione a spike sostituisce le moltiplicazioni con operazioni di *Accumulate* (AC) o *Synaptic Operations* (SOPs), in cui l'arrivo di uno spike discreto innesca solo un'addizione intera della carica o del peso sinaptico.

Una criticità per gli SNPS è la mancanza di hardware neuromorfico dedicato per la loro esecuzione diretta. Un approccio pratico consiste nel modellarne i consumi stimando le Synaptic Operations e mappando i meccanismi su chip neuromorfici per SNN (es. Intel Loihi 2 o SpiNNaker). Il lavoro non si limiterà alla sola architettura sviluppata finora per immagini, ma estenderà il confronto a diverse strutture di rete e dataset di benchmark per valutare l'impatto di diverse scelte progettuali [12].

6 Federated Learning e Privacy-Preserving Training

Tesi triennale o magistrale, SNPS

I dati utilizzati finora nelle sperimentazioni preliminari risultavano già strutturati e pronti all'uso. Tuttavia, gli scenari applicativi reali, come l'elaborazione di dati clinici, genomici o provenienti da dispositivi wearable, impongono severi vincoli di privacy e l'impossibilità di centralizzare le informazioni. In questo contesto, il Federated Learning (FL) rappresenta una soluzione ideale per addestrare modelli in modo distribuito mantenendo i dati sui dispositivi locali [14].

Gli SNPS offrono un vantaggio competitivo unico per il FL grazie al loro ridotto footprint di memoria. Per avere più informazioni specifiche si legga la sezione *Memory footprint* del paper presente nel repository al sopracitato **link**.

Invece di inviare dataset pesanti o rischiare la fuga di dati sensibili, è possibile trasmettere al server centrale esclusivamente le matrici dei pesi o la struttura discreta delle sinapsi. Inoltre, mentre nelle SNN ed ANN i nodi locali trasmettono pesi reali in virgola mobile, negli SNPS si opera su connessioni discrete e booleane $\{-1, 0, +1\}$, consentendo una drastica compressione del traffico di rete e vantaggi specifici per il green FL [13].

Esistono già primi tentativi di formalizzare SNPS orientati al privacy-preserving ed al Federated Learning, disponibili ai repository GitHub `https://github.com/miiip/Privacy-Presering-Spiking-Neural-P-System` e `https://github.com/miiip/Federated-LSNP`, legati al lavoro di Plesa et al. [10]. Tuttavia, si

tratta di approcci ancora incompleti, a testimonianza di un ambito di ricerca quasi inesplorato.

L'obiettivo della tesi è progettare ed analizzare un framework di Federated Learning basato su SNPS, affrontando scenari realistici caratterizzati da dati non-IID (distribuiti in modo disomogeneo tra i client) e risorse computazionali limitate sui nodi locali.

Bibliografia

[1] Saeedeh Akbari Rokn Abadi, Amirhossein Mohammadi, and Somayyeh Koohi. "WalkIm: Compact image-based encoding for high-performance classification of biological sequences using simple tuning-free CNNs". In: *Plos one* 17.4 (2022), e0267106.

[2] Simon Anders. "Visualization of genomic data with the Hilbert curve". In: *Bioinformatics* 25.10 (2009), pp. 1231–1235.

[3] Sales G Aribe Jr. "Spiking Neural Networks: The Future of Brain-Inspired Computing". In: ().

[4] Mihai Ionescu, Gheorghe Păun, and Takashi Yokomori. "Spiking neural P systems". In: *Fundamenta informaticae* 71.2-3 (2006), pp. 279–308.

[5] Hannah Franziska Löchel and Dominik Heider. "Chaos game representation and its applications in bioinformatics". In: (2021).

[6] Richard H Masland. "The neuronal organization of the retina". In: *Neuron* 76.2 (2012), pp. 266–280.

[7] Dubravko Miljković. "Brief review of self-organizing maps". In: *2017 40th international convention on information and communication technology, electronics and microelectronics (MIPRO)*. IEEE. 2017, pp. 1061–1066.

[8] Hong Peng et al. "Reservoir computing models based on spiking neural P systems for time series classification". In: *Neural Networks* 169 (2024), pp. 274–281.

[9] P Jonathon Phillips et al. "Four principles of explainable artificial intelligence". In: (2021).

[10] Mihail-Iulian Plesa, Marian Gheorghe, and Florentin Ipate. "Privacy-preserving Linear Computations in Spiking Neural P Systems". In: *arXiv preprint arXiv:2309.13803* (2023).

[11] Tao Song et al. "Spiking neural P systems with white hole neurons". In: *IEEE transactions on nanobioscience* 15.7 (2016), pp. 666–673.

[12] Martino Sorbaro et al. "Optimizing the energy consumption of spiking neural networks for neuromorphic applications". In: *Frontiers in neuroscience* 14 (2020), p. 662.

[13] Dipanwita Thakur et al. "Green federated learning: A new era of green aware AI". In: *ACM Computing Surveys* 57.8 (2025), pp. 1–36.

[14] Yeshwanth Venkatesha et al. “Federated learning with spiking neural networks”. In: *IEEE Transactions on Signal Processing* 69 (2021), pp. 6183–6194.

[15] Zuo-Bing Wu. “Recurrence plot analysis of DNA sequences”. In: *Physics Letters A* 332.3-4 (2004), pp. 250–255.

[16] Bojian Yin et al. “An image representation based convolutional network for DNA classification”. In: *arXiv preprint arXiv:1806.04931* (2018).

[17] Claudio Zandron. “An Overview on Applications of Spiking Neural Networks and Spiking Neural P Systems”. In: *Languages of Cooperation and Communication: Essays Dedicated to Erzsébet Csuhaj-Varjú to Celebrate Her Scientific Career* (2025), pp. 267–278.

[18] Yi Zeng et al. “Braincog: A spiking neural network based, brain-inspired cognitive intelligence engine for brain-inspired ai and brain simulation”. In: *Patterns* 4.8 (2023).

[19] Youdong Zhang et al. “Unsupervised spiking neural network based on liquid state machine and self-organizing map”. In: *Neurocomputing* 620 (2025), p. 129120.