



UNIVERSITÀ DEGLI STUDI DI PADOVA

Dipartimento di Psicologia Generale

Corso di Laurea Triennale in Scienze Psicologiche Cognitive e Psicobiologiche

Elaborato finale

**Intelligenza artificiale ispirata al cervello: Spiking Neural
Networks come modello di apprendimento biologicamente
plausibile**

**Brain-inspired artificial intelligence: Spiking Neural Networks as a biologically
plausible learning model**

Relatore

Prof. Marco Zorzi

Laureanda: Camilla Maria Tomasoni

Matricola: 2012218

Anno Accademico 2022-23

Indice

Sommario	4
Capitolo 1: Il neurone	5
1.1 Struttura del neurone	5
1.2 Composizione chimica della membrana	6
1.3 Potenziale di membrana a riposo	7
Capitolo 2: ANNs: Artificial Neural Networks	9
2.1 Paradigmi di apprendimento	9
2.2 Elementi chiave delle reti neurali	10
2.3 Schema di connettività	11
2.4 Regole di apprendimento	12
2.4.1 Feed-forward computation	12
2.4.2 Backpropagation	13
Capitolo 3: SNNs: Spiking Neural Networks	14
3.1 Dimensione spazio-tempo nel cervello	14
3.2 Dimensione spazio-temporale nelle reti neurali	16
3.3 Modelli di neuroni spiking	16
3.3.1 Spike Response Model	17
3.4 Applicazioni delle SNNs: Bio-inspired artificial vision systems	19
Conclusione	23
Riferimenti bibliografici	24

Sommario

Le Artificial Neural Networks (ANNs) sono un modello di apprendimento automatico che negli ultimi anni si sta affermando sempre di più, grazie al suo contributo in settori quali la Computer Vision e il Naturale Language Processing (NLP), e al supporto in diagnosi mediche, previsioni di mercato e decisioni finanziarie.

Inoltre, per quanto riguarda la più ampia disciplina dell'intelligenza artificiale, nell'ultimo decennio ci sono stati importanti sviluppi nella collaborazione tra neuroscienza e informatica, si veda ad esempio la costruzione di EBRAINS da parte dello Human Brain Project.

Lo scopo di questa tesi è fornire uno scorcio sulle tecnologie bio-inspired, operando un confronto tra il cervello umano e i sistemi artificiali, in particolare le Spiking Neural Networks (SNNs).

Nel dettaglio, il capitolo 1 presenta alcuni elementi di base della neurobiologia necessari per poter comprendere i contenuti successivi. Il capitolo 2 fornisce un'introduzione alle reti neurali descrivendone gli elementi principali. Infine, nel capitolo 3 sono illustrate le SNNs: ne viene presentato un modello e un esempio di applicazione, e la descrizione è accompagnata da riferimenti ai sistemi biologici al fine di operare un confronto.

Capitolo 1

Il neurone

1.1 Struttura del neurone

Il sistema nervoso è composto da due categorie di cellule: cellule gliali (o glia), e cellule nervose, che possono essere classificate in diverse tipologie sulla base di differenze strutturali.

Nel neurone prototipico si possono distinguere tre elementi strutturali principali:

- il soma. Costituisce il corpo cellulare, presenta una forma sferica dal diametro di circa 20 micrometri ed è avvolto da una membrana, chiamata membrana somatica. Contiene il nucleo e altri organuli necessari per sintetizzare lipidi e proteine (reticolo endoplasmatico liscio, reticolo endoplasmatico rugoso e apparato di Golgi).

L'interno del soma, costituito da citosol (soluzione salina ricca di potassio) è separato dall'ambiente extracellulare tramite la membrana neuronale che è un involucro di composizione proteica e spesso circa 5 nm.

- l'assone. E' un elemento morfologico che distingue il neurone dalle altre cellule, specializzato per il trasporto dell'informazione a distanza nel sistema nervoso. Presenta una parte iniziale, più vicina al soma, chiamata cono di integrazione, e una parte finale detta terminale (o bottone terminale), in cui l'assone viene a contatto con altre cellule. Lo spazio in cui avviene il contatto, e quindi il passaggio di informazione, è chiamato sinapsi.

L'assone non contiene al suo interno il reticolo endoplasmatico rugoso e di conseguenza non può effettuare la sintesi proteica ma solo trasportare proteine già sintetizzate in precedenza nel soma.

- i dendriti. Nel loro insieme formano una ramificazione chiamata albero dendritico che si estende a partire dal corpo cellulare e presenta diverse molecole di proteine specializzate, dette recettori, funzionali alla ricezione di informazioni da altre cellule (ricezione post-sinaptica).

Presentano una notevole eterogeneità in termini di dimensioni e ramificazione: alcuni neuroni sono sprovvisti di dendriti, altri presentano arborizzazioni complesse. Questa distinzione determina la capacità del neurone di integrare informazioni provenienti da diverse fonti, e quindi di elaborare stimoli più o meno complessi. Il numero di terminazioni ricevute da una cellula rappresenta il suo grado di convergenza, mentre il numero di target innervati da un neurone rappresenta il grado di divergenza.

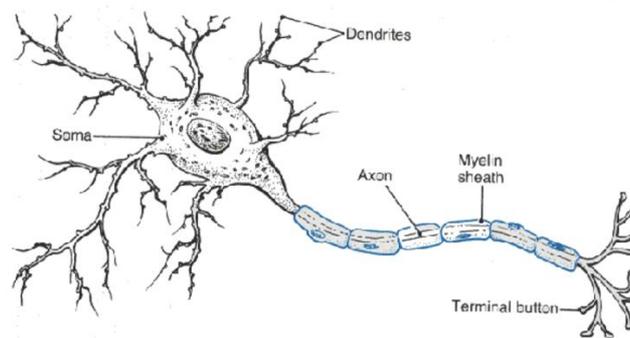


Figura 1: Rappresentazione di un neurone prototipico.

(Fonte: <https://www.neuroscienze.net/i-neuroni-e-le-cellule-gliali/>)

1.2 Composizione chimica della membrana

Il meccanismo di comunicazione dei neuroni si basa sulla trasmissione di segnali elettrici generati dal passaggio di ioni attraverso la membrana cellulare, che è costituita da un doppio strato di fosfolipidi e lungo la superficie presenta pompe ioniche e canali ionici che permettono ad alcune sostanze di attraversare la membrana. Inoltre, i canali presentano selettività ionica: esistono quindi canali specifici per gli ioni di potassio, sodio e calcio.

La semplice presenza di canali aperti non implica che ci sia un movimento di cariche, ma anzi il movimento degli ioni è determinato da due fattori:

- diffusione. Gli ioni tendono a spostarsi da zone ad alta concentrazione verso regioni a bassa concentrazione. Si dice che il movimento è dettato dal gradiente di concentrazione.

- elettricità. Gli ioni si spostano secondo il principio per cui cariche opposte si attraggono e cariche simili si respingono.

1.3 Potenziale di membrana a riposo

Grazie al lavoro dei canali e delle pompe ioniche e alla loro composizione proteica, gli ioni sono in continuo movimento attraverso la membrana e la differenza di carica elettrica tra l'interno e l'esterno della cellula è chiamata potenziale di membrana.

Quando i due flussi si equivalgono, generando una differenza costante di potenziale tra il citosol e l'ambiente extracellulare, si parla di potenziale di membrana a riposo, che varia generalmente tra i -40 mV e i -90 mV a seconda del tipo di neurone. In questa situazione, il citosol presenta una carica elettrica negativa rispetto all'esterno della cellula.

I potenziali d'azione consistono in variazioni momentanee del potenziale di membrana a riposo, e nei vari tipi di cellule sono generati in modo diverso. Ad esempio negli interneuroni la depolarizzazione della membrana che porta allo spike è data dal movimento degli ioni di sodio verso l'interno della cellula.

La frequenza di scarica e la distribuzione di tali impulsi elettrici rappresentano il codice usato dai neuroni per trasferire l'informazione.

Quando un potenziale d'azione arriva a una cellula, il lavoro della pompa sodio-potassio e dei canali rende l'interno del neurone carico positivamente rispetto all'esterno, provocando la depolarizzazione della membrana.

Se la depolarizzazione, chiamata anche potenziale generatore, raggiunge una certa soglia, darà luogo a un altro spike che si propaga alle cellule successive.

Analizzando la curva del potenziale d'azione è possibile distinguere:

- Fase ascendente. La membrana si depolarizza, ossia l'interno diventa carico positivamente rispetto all'ambiente extracellulare.
- Picco di depolarizzazione.
- Fase discendente. I canali del sodio si disattivano e il potassio inizia a fuoriuscire dalla cellula rendendo l'interno nuovamente negativo, causando la ripolarizzazione della membrana.
- Iperpolarizzazione. Fase in cui il potenziale di membrana è più negativo rispetto al valore di riposo.

- Periodo refrattario assoluto. Intervallo di tempo in cui i canali selettivi al sodio si disattivano a causa della depolarizzazione della membrana, impedendo quindi la generazione di un altro potenziale d'azione. Questa fase dura finché il potenziale di membrana non diventa abbastanza negativo da attivare nuovamente i canali.
- Periodo refrattario relativo. La membrana è iperpolarizzata e per raggiungere il valore di soglia è necessario uno stimolo più intenso.

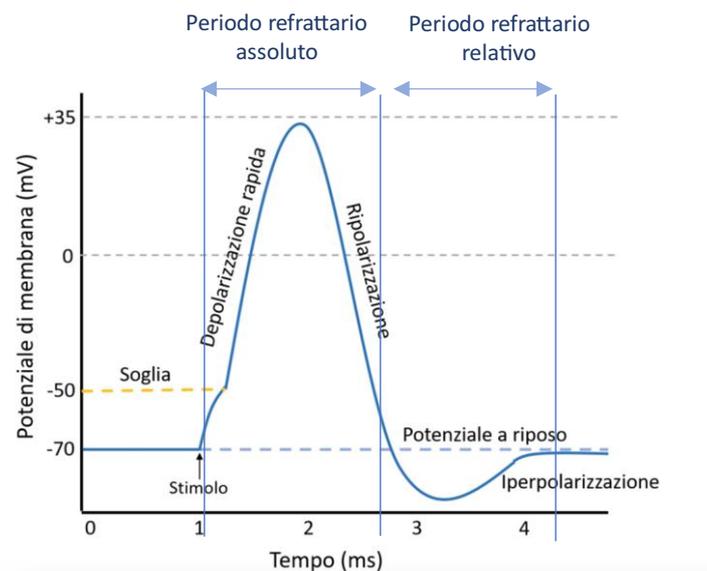


Figura 2. Curva di un potenziale d'azione in seguito a uno stimolo
 (Fonte: <https://www.biopills.net/potenziale-di-membrana-potenziale-azione/>)

Una volta generato, il potenziale d'azione si propaga lungo l'assone fino ad arrivare al terminale, dove l'informazione verrà trasferita al neurone successivo nel processo chiamato trasmissione sinaptica.

Capitolo 2

ANNs: Artificial Neural Networks

Le reti neurali sono un modello di machine learning ispirato al funzionamento biologico del cervello che supporta la ricerca in ambito neuroscientifico tramite simulazioni dell'attività cerebrale, e si pone come obiettivo quello di costruire macchine che emulino l'intelligenza umana.

In particolare, le Spiking Neural Networks, definite come la terza generazione di reti neurali (Maass, 1997), imitano i meccanismi biologici in modo più realistico rispetto alle reti tradizionali, fornendo uno strumento utile per l'analisi di processi cerebrali quali la plasticità sinaptica e il processamento di informazioni.

Prima di entrare nel dettaglio dei meccanismi *bio-inspired* occorre fornire le basi per la comprensione delle reti neurali tradizionali.

2.1 Paradigmi di apprendimento

Nel machine learning è possibile distinguere tre principali tipi di paradigmi di apprendimento:

- apprendimento supervisionato. È il paradigma di apprendimento più utilizzato nelle reti neurali. Durante l'addestramento, al modello vengono forniti i dati di input accompagnati dall'output desiderato (o target). Il learning consiste nell'apprendimento di una "funzione di ipotesi" h , che mette in relazione i dati di input e i relativi output.

La fase di test verifica la capacità di generalizzazione appresa dalla rete, che riceve in ingresso solamente i dati di input e deve essere in grado di restituire le etichette, cioè gli output, corrette.

Ad esempio, in compiti di classificazione di immagini, i dati in input sono vettori composti da numeri, ciascuno rappresentante un pixel, mentre ogni neurone di output identifica una classe. Lo scopo dell'apprendimento è che, fornita un'immagine, la rete attivi il neurone di output corrispondente alla classe corretta.

- apprendimento non supervisionato. I dati vengono forniti in input senza i relativi target e l'obiettivo dell'apprendimento è che la rete estrapoli informazioni significative e/o regolarità statistiche tramite l'"osservazione" dei dati forniti in ingresso.
- apprendimento per rinforzo. La rete si comporta come un agente che può operare sull'ambiente tramite una serie di azioni, in risposta alle quali riceve un rinforzo positivo o negativo. L'obiettivo è massimizzare una funzione delle ricompense.

2.2 Elementi chiave delle reti neurali

Nelle artificial neural networks si possono individuare i seguenti elementi:

- nodi, o neuroni artificiali. Sono le unità alla base delle reti neurali, ispirate alla struttura dei neuroni biologici. Ciascun nodo assume un valore numerico che corrisponde alla propria attivazione.
- *layers*. Le reti sono costituite da strati di neuroni interconnessi tra loro, che si distinguono in strato di input (riceve i dati in ingresso che verranno poi appresi dal modello) e strato di output (restituisce il prodotto dell'elaborazione della rete). Possono esserci anche uno o più strati nascosti che costituiscono un passaggio intermedio tra input e output, rendendo il modello più complesso e in grado di approssimare un range più ampio di funzioni. In presenza di almeno due strati nascosti si parla di *deep learning* (e *deep neural networks*, DNNs).
- *weights*, o pesi. Sono valori numerici associati alle connessioni tra i neuroni di diversi strati e descrivono la forza della connessione tra due nodi.

Tipicamente si indicano con la lettera greca Theta accompagnata da un apice e due indici $\theta^{(i)}_{jk}$, dove:

- i** indica lo strato da cui partono le connessioni,
- j** indica la posizione del neurone dello strato $i+1$,
- k** indica la posizione del neurone dello strato i .

Ad esempio, il peso $\theta^{(1)}_{34}$ fa riferimento alla connessione tra il quarto nodo del primo strato, e il terzo nodo del secondo strato.

Il simbolo $\theta^{(x)}$ indica il vettore contenente tutti i pesi che vanno dallo strato x allo strato $x+1$.

- *activation function*. La funzione di attivazione opera una trasformazione matematica sui valori in ingresso che determina l'attivazione di ciascuna unità. Una delle più note è la funzione sigmoide, una funzione continua e derivabile che restituisce come output un valore reale compreso tra 0 e 1: $f(x) = \frac{1}{1+e^{-x}}$

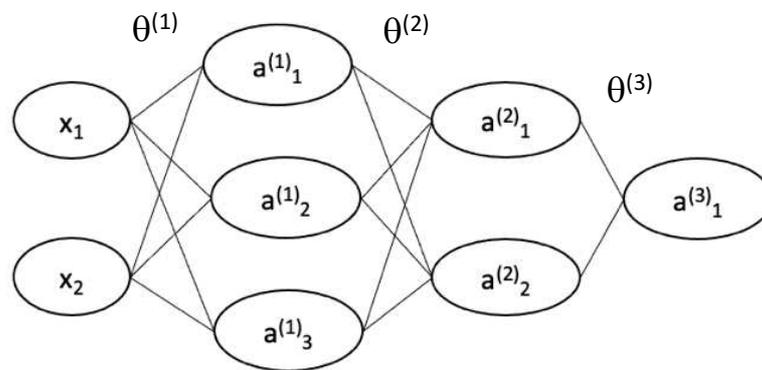


Figura 3. Rappresentazione di una rete neurale feed-forward, 2 strati nascosti formati rispettivamente da 3 e 2 neuroni, e 1 neurone nello strato di output.

2.3 Schema di connettività

Il modo in cui i neuroni dei diversi strati sono connessi tra loro distingue diverse tipologie di networks:

- *feed-forward*, in cui le informazioni si propagano solamente in avanti attraverso connessioni unidirezionali dall'input verso l'output.
- *recurrent*, che presentano connessioni di feedback che formano un ciclo, permettendo una sorta di conservazione della memoria della rete.
- *fully recurrent*, in cui oltre a connessioni bidirezionali ci sono connessioni laterali tra neuroni dello stesso strato.

2.4 Regole di apprendimento

Per descrivere il funzionamento di una rete neurale si farà ora riferimento al metodo di addestramento di un network feed-forward che utilizza un paradigma di apprendimento supervisionato.

L'obiettivo è che, alla fine della fase di training, il modello abbia adottato un'ottimale configurazione di pesi sinaptici tale da permettere una corretta propagazione dell'informazione.

In altre parole, la rete apprende per prove ed errori. Ad ogni *sample* del dataset di training la rete deve fornire una risposta. In base all'errore commesso, calcolato come differenza tra la risposta fornita dalla rete e il target, il modello modifica i propri pesi sinaptici per poi procedere allo stesso modo con altri dati, finchè non si raggiunge una performance accettabile.

Nel processo di apprendimento sono quindi identificabili due fasi: *feed-forward computation* (propagazione in avanti dell'informazione), e *backpropagation* (retropropagazione dell'errore, necessaria per la modifica dei pesi sinaptici).

2.4.1 Feed-forward computation

In un primo momento, i pesi vengono inizializzati in modo casuale e i neuroni di input si attivano assumendo un valore dipendente dai dati ricevuti in ingresso.

Ciascuna unità dello strato successivo si attiverà secondo la regola esposta di seguito. Facendo riferimento alla figura 3 (pg. 11), si prenda come esempio il secondo nodo del primo strato nascosto, $a^{(1)}_2$:

- viene calcolata una combinazione lineare moltiplicando ciascun valore di input per la propria connessione con il neurone $a^{(2)}_1$ e si fa la somma tra questi prodotti. Concettualmente, quello che si calcola è una somma pesata degli input; chiamiamo 'z' la combinazione lineare:

$$z = \theta^{(1)}_{11} x_1 + \theta^{(1)}_{12} x_2$$

- Il risultato di tale operazione viene passato alla funzione di attivazione f , e questo valore corrisponderà all'attivazione del nodo $a^{(1)}_2$.

$$a^{(1)}_2 = f(z)$$

I medesimi passaggi vengono eseguiti per tutti i neuroni degli strati restanti, fino ad arrivare alle unità di output e quindi alla risposta della rete.

2.4.2 Backpropagation

Dopo la fase di propagazione dell'attivazione, per poter procedere alla modifica dei pesi sinaptici, si applica l'algoritmo di backpropagation, che confronta la risposta prodotta dalla rete con il target desiderato.

L'errore commesso, che si misura tramite una *cost function* (funzione di costo), viene retro-propagato all'indietro lungo le connessioni, e i pesi sinaptici vengono modificati.

Si ripetono alternativamente la fase feed-forward e la backpropagation fino a quando l'errore commesso dalla rete non tende a 0, o a un valore sufficientemente piccolo da essere accettato.

Capitolo 3

Spiking Neural Networks

Una delle maggiori differenze tra le SNNs e le reti tradizionali è che le prime includono i concetti di tempo e spazio nell'apprendimento, attraverso l'uso di pattern spazio-temporali di spikes. Questo porta le reti spiking ad essere più biologicamente realistiche, in quanto il concetto del tempo è un elemento fondamentale alla base della comunicazione nel sistema nervoso.

3.1 Dimensione spazio-temporale nel cervello

L'importanza della dimensione temporale nei meccanismi biologici di apprendimento emerge principalmente da due elementi.

Anzitutto, occorre considerare come l'informazione che si propaga nel cervello a partire dai cinque sensi sia sempre di tipo spazio-temporale. Uno stimolo, infatti, può essere descritto come una sequenza di eventi che accadono in un certo spazio e in un certo istante.

A scopo esemplificativo si riporta di seguito il percorso che dà origine alla percezione del gusto, usando i simboli E_i per indicare gli eventi, S_i per gli spazi, T_i per gli istanti temporali. La sensazione del gusto ha origine a partire dalle cellule recettrici poste sulla superficie della lingua, che rispondono agli stimoli chimici ed effettuano la trasduzione (E_1, S_1, T_1). Da lì il segnale elettrico arriva ai calici gustativi (E_2, S_2, T_2), dai quali, tramite gli assoni del tronco encefalico arriva al talamo (E_2, S_2, T_2), e poi alla corteccia (E_3, S_3, T_3).

In secondo luogo, un altro aspetto che rimanda all'importanza della dimensione temporale nel cervello riguarda la comunicazione tra neuroni attraverso impulsi elettrici. Gli stimoli, definibili come cambiamenti spazio-temporali nell'ambiente, vengono codificati dai neuroni come eventi binari (spikes). Sebbene ci sia un dibattito in ambito neuroscientifico in merito al modo in cui l'informazione sia codificata, sono stati individuati due possibili codici di rappresentazione neurale:

- *rate-based encoding*, che a causa delle diverse possibili interpretazioni del termine “rate” si divide a sua volta in:
 - i) *temporal average rate*. L’informazione è codificata dalla media degli spikes avvenuti in un certo intervallo di tempo, oppure dalla frequenza media di spiking.
 - ii) *rate as a population average*. Numero medio di spikes in una popolazione di neuroni.

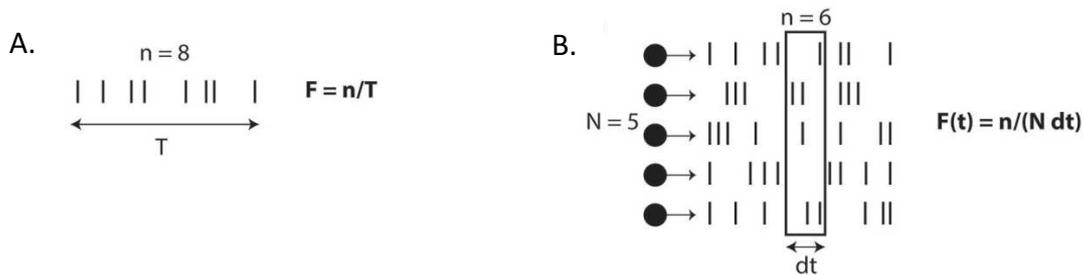


Figura 4. Definizioni di firing rate: *rate as a temporal average* (A), *rate as a population average* (B)
 (Fonte: R. Brette, *Philosophy of the spike: Rate-based vs Spike-based theories of the brain*, 2015)

- *spike-based encoding*. Teoria secondo cui l’informazione è codificata negli istanti esatti in cui sono avvenuti gli impulsi. In questo caso sono stati identificati tre possibili schemi di rappresentazione:
 - i) *time to the first spike*. La parte importante dell’informazione relativa allo stimolo risiede nel periodo di latenza tra l’arrivo dello stimolo e l’istante in cui viene generato il primo spike, mentre gli spikes successivi sono ignorati.
 - ii) *phase coding*. Quando il segnale non è singolo ma è periodico (un’onda), l’informazione relativa allo stimolo è codificata negli istanti in cui vengono generati gli spike, con riferimento all’oscillazione sottostante. Due stimoli diversi elicitano risposte diverse, che possono essere discriminate in base alla fase dell’oscillazione sottostante in cui generano lo spike.
 - iii) *synchronization*. Si basa sull’idea che neuroni che sparano in modo sincronizzato rappresentino features diverse dello stesso oggetto.

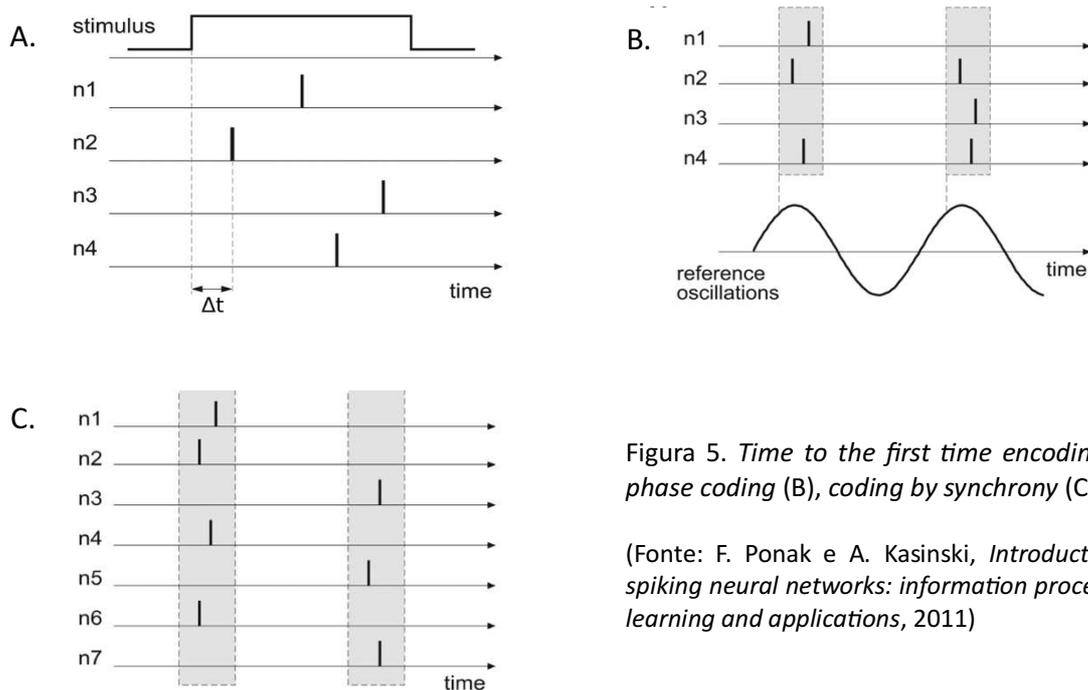


Figura 5. *Time to the first time encoding* (A), *phase coding* (B), *coding by synchrony* (C).

(Fonte: F. Ponak e A. Kasinski, *Introduction to spiking neural networks: information processing, learning and applications*, 2011)

3.2 Dimensione spazio-temporale nelle reti neurali

Le reti neurali di seconda generazione descritte nel capitolo 2 utilizzano un codice neurale di tipo rate-based, infatti il valore numerico reale che descrive l'attivazione di ciascun nodo può essere visto come una misura della frequenza di scarica del neurone.

Per diversi anni in ambito neuroscientifico si è pensato che questo tipo di rappresentazione fosse quello corretto, fino ad alcune ricerche degli anni 90 e 2000 (Abeles e Bergman, 1993; Lestienne, 2001) che hanno mostrato come invece la codifica spike-based fosse più plausibile nel cervello. Queste scoperte hanno portato allo sviluppo di una terza generazione di reti neurali spiking, più potenti e meno costose in termini di risorse computazionali.

3.3 Modelli di spiking neural networks

Esistono diversi modelli di spiking neural networks che differiscono per architettura, algoritmo di apprendimento, complessità computazionale e codice di rappresentazione dell'informazione. Tuttavia, tutti i modelli presentano alcune caratteristiche in comune con i circuiti biologici.

In primis le reti neurali spiking elaborano informazioni provenienti da più siti, corrispondenti ai dendriti, e producono in output dei segnali di spiking. In secondo luogo anche nelle reti artificiali esiste la distinzione tra sinapsi inibitorie ed eccitatorie, che rispettivamente diminuiscono ed aumentano la probabilità di generare uno spike nel neurone post-sinaptico. Infine, anche i network artificiali sono caratterizzati da almeno uno stato variabile che determina la scarica del potenziale d'azione, che nel caso dei neuroni biologici è la membrana.

I modelli di neuroni spiking si suddividono in *detailed* e *formal models*. I primi riproducono in modo più accurato i processi elettrofisiologici della cellula che generano i potenziali, ma a causa della elevata complessità sono difficili da analizzare e richiedono costi computazionali più alti. La seconda tipologia di modelli, invece, descrive il meccanismo della comunicazione tra i neuroni in maniera più semplificata, trattando lo spike come un evento singolo ma senza descriverne le cause elettrofisiologiche.

In questo capitolo verrà presentato il *formal Spike Response Model (SRM)*.

3.3.1 Spike Response Model

Lo Spike Response Model è un modello matematico che descrive il comportamento di un neurone artificiale, ispirato ai concetti biologici di soglia e potenziale post-sinaptico.

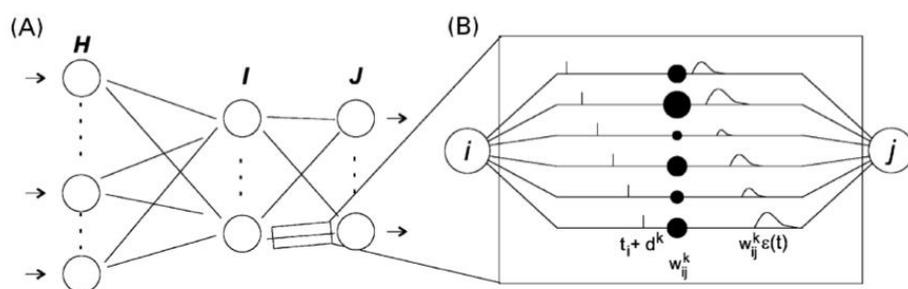


Figura 6. Struttura di una feed-forward spiking neural network.

(Fonte: S.M. Bohte et al., *Error-backpropagation in temporally encoded networks of spiking neurons*, 2002)

La figura 5 mostra una rete spiking feed-forward, in cui le lettere H, I e J indicano rispettivamente lo strato di input, lo strato nascosto e lo strato di output; e le lettere minuscole h, i e j fanno riferimento alle unità di ciascuno strato.

Per ogni nodo j esiste un set Γ_j costituito dai neuroni presinaptici (le unità dello strato I), e ciascuno dei neuroni genera uno spike quando la sua variabile interna $x(t)$ raggiunge la soglia. Di conseguenza, il neurone post-sinaptico j riceve in input un set di spikes, dove t_i indica l'istante di scarica del neurone i .

Il valore dello stato variabile del neurone post-sinaptico è individuato con la formula seguente:

$$x_j(t) = \sum_{i \in \Gamma_j} w_{ij} \varepsilon(t - t_i). \quad (1)$$

L'equazione (1) dice che il "potenziale di membrana" ($x(t)$) del neurone artificiale j corrisponde alla somma pesata (cioè moltiplicata per le connessioni w) di tutti gli input ricevuti, a cui è stata applicata la funzione ε . Quest'ultima, chiamata funzione di risposta allo spike, descrive il potenziale post-sinaptico (PSP) che si genera nel neurone j dopo aver ricevuto gli spikes dai neuroni dello strato I, ed è definita in tal modo:

$$\varepsilon(t) = \frac{t}{\tau} e^{1-t/\tau} \quad (2)$$

dove τ è un parametro che descrive il tempo di decadimento del potenziale post-sinaptico.

Poiché in un'architettura spiking ogni connessione è costituita da diverse sotto-connessioni, chiamate terminali sinaptici, ciascuna con il proprio peso e il proprio istante di generazione dello spike (figura 5.B), la regola di propagazione va modificata. Il contributo (non pesato) di ciascun terminale sinaptico k è descritto dalla seguente formula:

$$y_i^k(t) = \varepsilon(t - t_i - d^k) \quad (3)$$

dove d^k indica il ritardo del terminale k , definito come la differenza tra t_i (il momento di scarica del neurone presinaptico) e l'istante in cui inizia ad aumentare il potenziale post-sinaptico.

Tenendo conto di tutti i terminali m , l'equazione (1), che descrive il comportamento dello stato variabile, diventa:

$$x_j(t) = \sum_{i \in \Gamma_j} \sum_{k=1}^m w_{ij}^k y_i^k(t) \quad (4)$$

Quando $x_j(t)$ supera il valore di soglia, il neurone j genera un potenziale d'azione.

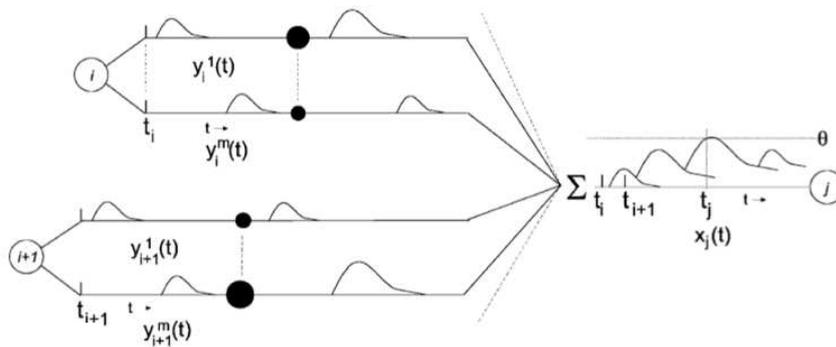


Figura 7. Rete neurale spiking con due connessioni sinaptiche entrambe formate da due terminali. Nella parte destra dell'immagine si vede il PSP dato dai quattro potenziali d'azione in input, e il raggiungimento della soglia θ .

(Fonte: S.M. Bohte et al., *Error-backpropagation in temporally encoded networks of spiking neurons*, 2002)

3.4 Applicazioni delle SNNs: Bio-inspired artificial vision systems

Uno degli ambiti di applicazione delle SNNs è la *Computer vision*, ossia il campo dell'intelligenza artificiale che si occupa di sviluppare algoritmi e metodi per riprodurre nelle macchine i processi di elaborazione visiva del cervello umano.

Tra i recenti sviluppi nel settore ci sono sicuramente le *Event-Based Cameras* (o DVS, *Dynamic Vision Sensor*): sensori *bio-inspired* capaci di catturare la scena visiva con una risoluzione temporale più alta rispetto ai sensori tradizionali e un consumo di energia significativamente minore. Questa nuova tecnologia, combinata con le SNNs, ha dato il via a una serie di studi orientati alla costruzione di sistemi di visione artificiale *bio-inspired*, che si sono rivelati utili in compiti di computer vision quali la classificazione di immagini, previsione di traiettorie e detezione di oggetti.

Le telecamere event-based, a differenza di quelle tradizionali che acquisiscono intere immagini a una frequenza prestabilita (*fps*, *frames per second*), operano in modo asincrono. Ogni pixel, in modo asincrono e indipendente dagli altri pixel, tiene traccia della luminosità della scena visiva. Quando avviene un cambiamento di luminosità abbastanza intenso da superare una determinata soglia, il pixel invia un segnale binario, chiamato “evento”, descritto da delle coordinate spaziali (x,y) , da un istante t , e da 1 bit che può assumere due valori (per indicare se c'è stato un incremento o un decremento nell'illuminazione).

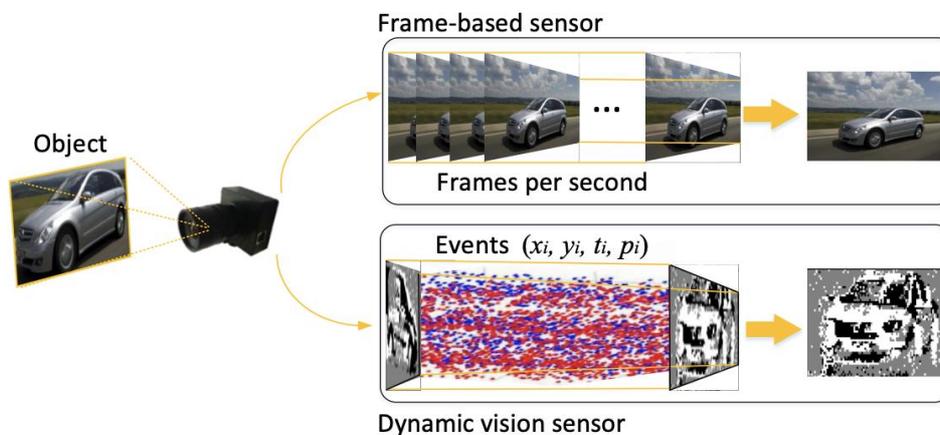


Figura 8. Differenza tra una frame-based camera e una event-based camera.

(Fonte: S: Gao et al., *An end-to-end broad learning system for event-based object classification*, 2020)

I sensori event-based forniscono numerosi vantaggi ai sistemi di visione artificiale. Anzitutto, garantiscono una risoluzione temporale maggiore, poiché i segnali sono rilevati e registrati nell'ordine dei microsecondi, permettendo la rilevazione di movimenti molto rapidi nella scena visiva e una maggiore nitidezza. In secondo luogo, essendo una

tecnologia data-driven, i sensori trasmettono in output soltanto i cambiamenti di luminosità invece che tutta l'immagine, abbassando il consumo di energia e rendendo il processo più economico. Infine, le event cameras sono più rapide delle telecamere tradizionali, poiché ogni pixel opera in modo indipendente dall'altro inviando il proprio segnale appena rileva un cambiamento di illuminazione, senza dover attendere una visione globale dell'immagine.

Nonostante i benefici, la visione artificiale event-based è un campo di studi recente e ancora in espansione, e ci sono ancora alcune problematiche irrisolte. In particolare, una delle sfide legate alle event cameras riguarda l'estrazione di informazione dai segnali provenienti dai pixel: essendo i segnali binari asincroni e sparsi nello spazio, i metodi di processamento studiati per le frame-based cameras, che ricevono sequenze di immagini sincrone, non sono adattabili ai sensori event-based.

Una delle soluzioni a tale problema riguarda l'utilizzo di spiking neural networks implementate su piattaforme neuromorfe, cioè architetture hardware ispirate al sistema di elaborazione cerebrale. Le SNNs, infatti, grazie alla loro dimensione temporale, sono particolarmente adatte al processamento di dati spazio-temporali.

A dimostrazione di quanto esposto finora, si riportano i risultati di uno studio (Debat et al., 2021) condotto di recente in cui una rete artificiale spiking è stata testata in un compito di predizione della traiettoria di una palla.

La ricerca prevedeva una SNN addestrata con la regola di apprendimento STDP (Spike Time Dependant Plasticity) e un paradigma di apprendimento non supervisionato. L'obiettivo era che durante la fase di training la rete apprendesse le features delle traiettorie presentate (direzione, velocità, forma), fino a poter prevedere il punto di caduta di una palla.

La figura 9 confronta la performance umana e la performance della rete artificiale, misurata come errore medio assoluto. L'asse delle ascisse riporta la variabile "visibilità della traiettoria", cioè la percentuale della traiettoria che veniva mostrata ai partecipanti.

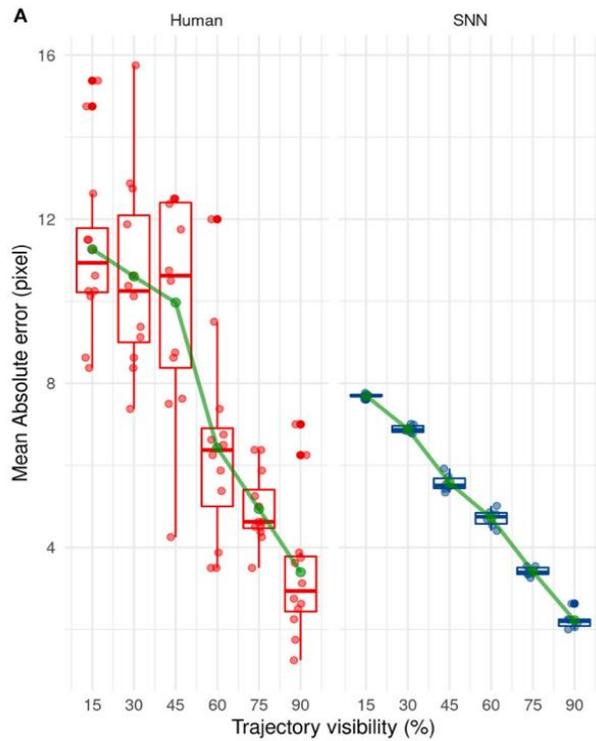


Figura 9. Andamento dell'errore medio assoluto dipendentemente dalla percentuale di traiettoria mostrata.

(Fonte: G. Debat et al., *Event-Based Trajectory Prediction Using Spiking Neural Networks*, 2021)

Come si può osservare dal grafico, la rete ha ottenuto risultati migliori dei partecipanti a tutti i livelli della variabile di visibilità, con un maggiore distacco nella performance associata a visibilità bassa (15%, 30%, 45%). Dunque, i risultati mostrano un esempio di come le SNNs possano essere utilizzate a supporto dei sistemi di visione artificiale per estrarre informazioni spazio-temporali in modo accurato.

Conclusione

Oltre al contributo nell'ambito della visione artificiale, come riportato nel capitolo 3, le reti spiking presentano alcuni vantaggi rispetto alle reti tradizionali.

In primis, le reti spiking, rispetto a quelle tradizionali, hanno il vantaggio di poter processare in modo più accurato stimoli temporali. In particolare, l'avanzare degli studi nell'ambito dell'ingegneria neuromorfica, orientati a sviluppare supporti hardware senza separazione tra unità computazionale e memoria, e con maggiore grado di parallelismo, sta dando un'ulteriore spinta all'utilizzo delle reti spiking, rendendole più efficienti dal punto di vista del consumo di energia.

Inoltre, ricerche degli ultimi anni sulle reti neurali hanno permesso di superare uno dei limiti che per molto tempo aveva rallentato lo sviluppo delle SNNs, ossia la difficoltà di trovare una regola di apprendimento compatibile con il meccanismo d'azione dei potenziali d'azione. Vi era, infatti, la necessità di trovare un algoritmo di apprendimento che sostituisse il *gradient descent*, il cui calcolo delle derivate parziali non si applicava a segnali binari discreti. Le ricerche in tale direzione hanno portato ad alcune soluzioni soddisfacenti, tra cui: la *ANNs-to-SNN conversion*, in cui reti tradizionali sono addestrate con l'algoritmo di backpropagation, e successivamente i neuroni sono trasformati in neuroni spiking; e la STDP (*spike-time dependent plasticity learning*), in cui la regola di aggiornamento dei pesi si basa sulla dipendenza temporale tra lo spike pre-sinaptico e post-sinaptico.

Attualmente, le reti spiking sono ancora una tecnologia in piena fase di sviluppo, e pertanto presentano una serie di limiti non ancora superati. Come riportato precedentemente, grazie anche allo sviluppo di nuovi metodi di apprendimento e di supporti neuromorfici, è possibile che le reti spiking prenderanno sempre più piede, rivoluzionando la ricerca nell'ambito dei sistemi di intelligenza artificiale brain-inspired.

Riferimenti bibliografici

- [1] Aggarwal, C. C. (2018). *Neural Networks and Deep Learning: A textbook*. Springer (1° edizione).
- [2] Bear, M. F., Connors, B. W., & Paradiso, M. A. (2016). *Neuroscienze. Esplorando il cervello*. Edra (4° edizione).
- [3] Bohte, S. M., Kok, J. N. & La Poutré, H. (2002). Error-backpropagation in temporally encoded networks of spiking neurons. In *Neurocomputing* (Vol. 48, Issues 1- 4)
- [4] Brette, R. (2015). Philosophy of the Spike: Rate-Based vs Spike-Based Theories of the Brain. In *Frontiers in Systems Neuroscience* (Vol. 9).
- [5] Colucci D'amato, L., Di Porzio, U. (2011). *Introduzione alla neurobiologia*. Springer Verlag.
- [6] Debat, G., Chauhan, T., Cottureau, B. R., Masquelier, T., Paindavoinde, M. & Baures, R. (2021). Event-Based Trajectory Prediction Using Spiking Neural Networks. In *Frontiers Computational Neuroscience* (Vol. 15)
- [7] Gallego, G., Delbruck, T., Bartolozzi, C., Censi, A., Davison, A. J., Daniilidis, K. & Scaramuzza, D. (2022). Event-Based Vision: A Survey. In *IEE transactions on pattern analysis and machine intelligence* (Vol. 44 No. 1).
- [8] Gao, S., Guo, G., Huang, H., Cheng, X. & Chen, C. L. P. (2020). An End-to-End Broad Learning System for Event-based Object Classification. In *IEEE Access* (Vol. 8)
- [9] Gerstner, W., Kistler, W. M. (2002). *Spiking Neuron Models: Single neurons, populations, plasticity*. Cambridge University Press.
- [10] Graupe, D. (2019). *Principles of artificial neural networks: basic designs to deep learning*. World Scientific (4° edizione).
- [11] Kasabov, N. (2019). Time-Space, Spiking Neural Networks and Brain-inspired artificial intelligence. In *Springer Series on Bio- and Neurosystems* (Vol. 7), pp. 1-164

- [12] Lobo, J. L., Del Ser, J., Bifet, A., & Kasabov, N. (2019). Spiking Neural Networks and online learning: an overview and perspectives. In *Neural Networks* (Vol. 121), pp. 88-100
- [13] Maass, W. (1997). Networks of Spiking Neurons: The Third Generation of Neural Network Models. In *Neural Networks* (Vol. 10), pp. 1659-1671
- [14] Matelli, M., Umiltà, C. (2007). *Il cervello. Anatomia e funzione del sistema nervoso centrale*. Il mulino.
- [15] Ponulak, F., & Kasiński, A. (2011). Introduction to spiking neural networks: Information processing, learning and applications. In *Acta Neurobiologiae Experimentalis* (Vol. 71 No. 4), pp. 409-433
- [16] Sekhar, C. (2020). A study on Backpropagation in Artificial Neural Networks. In *Asia-Pacific Journal of Neural Networks and Its Applications* (Vol. 4 No. 1).
- [17] Yamazaki, K., Vo-Ho, V., Bulsara, S., & Le, N. (2022). Spiking Neural Networks and Their Applications: A review. In *Brain Sciences* (Vol. 12 Issue 7).