



**UNIVERSIDADE FEDERAL DO CEARÁ**  
**CENTRO DE CIÊNCIAS**  
**DEPARTAMENTO DE FÍSICA**  
**CURSO DE FÍSICA**

**ESTER ALVES LEMOS**

**FORMAÇÃO DE CLUSTER DE MEMÓRIA CEREBRAL NO APRENDIZADO**

**FORTALEZA**

**2025**

ESTER ALVES LEMOS

FORMAÇÃO DE CLUSTER DE MEMÓRIA CEREBRAL NO APRENDIZADO

Trabalho de Conclusão de Curso de Graduação apresentada à Coordenação da Graduação do Curso de Física, da Universidade Federal do Ceará, como requisito parcial para a obtenção do Título de Licenciada em Física.

Orientadora: Profa. Dra. Wanêssa Façanha da Silva.

FORTALEZA  
2025

Dados Internacionais de Catalogação na Publicação  
Universidade Federal do Ceará  
Sistema de Bibliotecas  
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

---

L576f Lemos, Ester Alves.

Formação de Cluster de Memória Cerebral no Aprendizado / Ester Alves Lemos. – 2025.  
55 f. : il. color.

Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Centro de Ciências,  
Curso de Física, Fortaleza, 2025.

Orientação: Profa. Dra. Wanêssa Façanha da Silva.

1. Redes Neurais. 2. Dinâmica de Memória. 3. Formação de Pensamento. 4. Cluster Sináptico. I. Título.  
CDD 530

---

ESTER ALVES LEMOS

FORMAÇÃO DE CLUSTER DE MEMÓRIA CEREBRAL NO APRENDIZADO

Trabalho de Conclusão de Curso de Graduação apresentada à Coordenação da Graduação do Curso de Física, da Universidade Federal do Ceará, como requisito parcial para a obtenção do Título de Licenciada em Física.

Aprovado em 25 de julho de 2025.

BANCA EXAMINADORA

---

Profa. Dra. Wanêssa Façanha da Silva (Orientadora)  
Universidade Federal do Ceará (UFC)

---

Me. Raabe Melo de Oliveira  
Universidade Federal do Rio Grande do Norte (UFRN)

---

Dra. Leidy Milena Leal Abril  
Universidade Federal do Ceará (UFC)

Ao meu eu do passado, que merece essa conclusão.

## AGRADECIMENTOS

Agradeço, em primeiro lugar, aos meus pais, Weliton e Irenice (Nicinha), por sempre valorizarem a educação e me incentivarem a estudar com dedicação e curiosidade. Suas palavras, gestos, trabalho e cuidado me sustentaram em todos os momentos, e esta conquista também é de vocês. À minha avó Letícia, pelo acolhimento e apoio, especialmente na pandemia, quando sua casa se tornou também meu espaço de estudo, silêncio e foco.

Aos meus professores da EEEP Professor Francisco Aristóteles de Sousa, que me mostraram, ainda no ensino médio, que o conhecimento transforma realidades e que o esforço vale a pena.

Aos colegas da graduação, pelo apoio mútuo, pelas conversas, pelos cafés, pelas trocas de material e pelas risadas nos momentos mais necessários. Durante a universidade, tive o privilégio de conhecer pessoas que marcaram profundamente minha caminhada. Em especial, agradeço à Kris Moura e ao Mateus Falcão, amigos de verdade que estiveram presentes em muitos momentos. Ao meu namorado, Herberth Nogueira, que além de ser um companheiro incrível, foi imprescindível na etapa final da graduação, me dando apoio e conforto.

Agradeço ao corpo docente do curso de Física da UFC e dos demais departamentos que também integraram minha formação ao longo da graduação. Em especial, ao professor Antonio Gomes de Souza Filho, com quem cursei diversas disciplinas, me orientou em todos os meus estágios e iniciei minha trajetória na pesquisa científica. Sua história de vida é uma inspiração e um exemplo que carrego comigo.

À professora Wanêssa Façanha da Silva, minha orientadora, por sua dedicação incansável, sua escuta atenta e sua gentileza em cada orientação. Com sua incrível competência e sensibilidade, me acompanhou em todas as etapas, e sua confiança no meu trabalho foi fundamental para que esta monografia alcançasse a forma que tem hoje. Sou profundamente grata por todo o cuidado e carinho e por tudo que aprendi com você.

Em memória do professor Antônio Tavares Bittencourt (Bit), que me orientou no PIBID do Liceu do Ceará e foi um grande mestre. Realista, apaixonado pela ciência e pela educação, deixou marcas profundas na minha formação. Sua influência permanece viva em mim.

Por fim, agradeço à CAPES, pelo apoio no Programa Institucional de Bolsa de Iniciação à Docência (PIBID), e ao CNPq, pela oportunidade de atuar na Iniciação Científica (PIBIC). Ambas as experiências foram fundamentais para minha formação acadêmica e profissional, ampliando meu contato com a pesquisa e a prática docente.

## RESUMO

A neurociência contempla um campo vasto de análise dinâmica dos sistemas neurais. Devido à complexidade dessas redes, associada à propagação de sinais de informação e à formação de agrupamentos sinápticos otimizados, investigamos o comportamento do potencial de ação no corpo neuronal em função da corrente externa, tomada como função estímulo. A partir da análise gráfica do potencial de ação gerado por diferentes funções matemáticas que modelam essa corrente, formalizamos a hipótese de que o surgimento de *spikes* está relacionado à formação de linhas de raciocínio complexas e periódicas, enquanto sua ausência indica redução da eficiência sináptica, correlacionada a processos cognitivos menos robustos. Com isso, demonstramos que estímulos como leitura, jogos educativos e o aprendizado por meio de linguagens de programação potencializam a atividade neuronal associada a processos cognitivos complexos, sustentados e com maior integração funcional.

**Palavras-chave:** redes neurais; dinâmica de memória; formação de pensamento; cluster sináptico.

## ABSTRACT

Neuroscience encompasses a vast field of dynamic analysis of neural systems. Due to the complexity of these networks, associated with the propagation of information signals and the formation of optimized synaptic clusters, we investigated the behavior of the action potential in the neuronal body as a function of the external current, taken as the stimulus function. From the graphical analysis of the action potential generated by different mathematical functions that model this current, we formalized the hypothesis that the emergence of spikes is related to the formation of complex and periodic lines of reasoning, while their absence indicates reduced synaptic efficiency, correlated with less robust cognitive processes. With this, we demonstrate that stimuli such as reading, educational games, and learning programming languages enhance neuronal activity associated with complex, sustained cognitive processes with greater functional integration.

**Keywords:** neural networks; memory dynamics; thought formation; synaptic cluster.

## LISTA DE FIGURAS

- Figura 1 – Representação da estrutura de subpopulações neuronais em redes neurais recorrentes treinadas para diferentes tarefas cognitivas. A figura mostra que, mesmo quando os estímulos de entrada são semelhantes, redes treinadas para tarefas distintas organizam seus neurônios de forma diferenciada, evidenciando padrões específicos de seletividade e conectividade. Esses padrões formam estruturas internas que não ocorrem ao acaso, refletindo a adaptação funcional da rede às exigências de cada tarefa. . . . . 19
- Figura 2 – Esquema ilustrativo de diferentes tipos de códigos populacionais neurais e suas possíveis funções cognitivas. A figura compara padrões de disparo com e sem correlação entre os neurônios e associa cada tipo de estrutura a modos distintos de processamento de informação. Códigos com correlações organizadas entre neurônios com propriedades similares tendem a favorecer a fidelidade representacional e o armazenamento transitório da informação, enquanto padrões mais ruidosos podem estar associados à flexibilidade cognitiva ou ao processamento sensorial rápido. . . . . 20
- Figura 3 – Comparação entre sinais reais de EEG e as saídas geradas por uma rede neural recorrente com disparo treinada pelo algoritmo *modified-FORCE*. Os traçados em azul representam os sinais de EEG obtidos experimentalmente, enquanto os traçados em vermelho correspondem às respostas da rede simulada. A figura evidencia a semelhança temporal entre os padrões reais e simulados, sugerindo que a rede foi capaz de aprender as dinâmicas temporais complexas presentes nos sinais biológicos. . . . . 21

- Figura 4 – Visualização de trajetórias neurais simuladas em um sistema composto por dez nós acoplados. O painel A exibe as séries temporais dos dez nós simulados (acima), seguidas da mesma informação em forma de mapa de calor (abaixo), facilitando a identificação dos padrões dinâmicos. Nessa configuração, os dois nós principais, que compõem o sistema biestável, alternam entre estados de ativação alta e baixa, enquanto os demais nós oscilam ritmicamente em resposta ao estado dominante da rede. O painel B apresenta os mesmos dados após uma transformação ortogonal, que reorganiza a atividade da rede de forma que as dinâmicas originais, como as oscilações e a biestabilidade, tornam-se invisíveis na leitura direta dos sinais dos nós. Essa transformação evidencia como estruturas de baixa dimensionalidade, conhecidas como *manifolds*, podem estar embutidas em redes mais complexas e só se tornam acessíveis por meio de representações projetadas. . . . . 22
- Figura 5 – Representação de um modelo de rede neural recorrente (*Recurrent Neural Network*, RNN) composto por unidades excitatórias (círculos vermelhos) e inibitórias (círculos azuis), treinado para executar a tarefa de *Delayed Match to Sample* (DMS, tarefa de correspondência retardada). No painel à esquerda (a), são apresentados a estrutura da rede e os sinais de saída produzidos pela RNN treinada, incluindo gráficos dos disparos neuronais durante a janela de estímulo (área sombreada em cinza). O painel à direita (b) mostra dados experimentais obtidos em macacos submetidos à tarefa espacial de DMS, com registros de disparos neuronais no córtex pré-frontal dorsolateral durante tentativas de acerto e erro. . . . . 24
- Figura 6 – Representação esquemática dos mecanismos de LTP e LTD mediados por diferentes concentrações de cálcio intracelular em uma sinapse do hipocampo. Estímulos de alta frequência favorecem LTP, enquanto estímulos de baixa frequência induzem LTD. . . . . 25
- Figura 7 – Modelo computacional de rede neural recorrente esparsa (RSNN), no qual a aprendizagem eficiente é obtida com baixa plasticidade sináptica, baseada apenas na sincronização temporal dos disparos neuronais. A imagem mostra a evolução temporal das variáveis internas  $\varphi_1$  e  $\varphi_2$  de dois neurônios durante a execução da tarefa. . . . . 26
- Figura 8 – Distribuição de atividade de dois neurônios durante a codificação de um estímulo, destacando a sincronia funcional entre eles. As regiões diagonais evidenciam a consistência da informação, exemplificando como múltiplos grupos de neurônios podem operar de forma coordenada em tarefas cognitivas. 27

Figura 9 – Representação esquemática dos mecanismos de LTP e LTD em sinapses do hipocampo. A intensidade do estímulo modula a concentração de cálcio, determinando a direção da plasticidade sináptica. . . . .	29
Figura 10 – Organização compartimentalizada de sinapses coativas em um dendrito de neurônio cortical, evidenciada por imagem de fluorescência em resposta à estimulação sensorial. . . . .	30
Figura 11 – Aprendizado baseado em recompensa de uma rede neural recorrente baseada em <i>spikes</i> (RSNN) sem plasticidade sináptica durante a execução. (A,B) Exemplos de trajetórias de navegação antes e depois do treinamento; (C) Dinâmica da rede durante o comportamento; (D) Arquitetura da RSNN; (E) Curvas de aprendizado mostrando variação no número de metas atingidas e no comprimento dos caminhos. . . . .	31
Figura 12 – Reorganização temporal de uma rede de células de engrama: o aprendizado ativa conjuntos específicos de neurônios em regiões como o hipocampo, o córtex e áreas subcorticais. A consolidação envolve fortalecimento sináptico entre essas células e reorganização da rede com maior dependência do córtex para evocação da memória remota. . . . .	32
Figura 13 – Representação do crescimento exponencial do potencial dendrítico para $I_{d_{ext}}^t = I_0$ . . . . .	37
Figura 14 – Representação do crescimento exponencial do potencial dendrítico para $I_{d_{ext}}^t = I_0 H(0)$ . . . . .	37
Figura 15 – Variações da representação do crescimento exponencial do potencial dendrítico para $I_{d_{ext}}^t = I_0$ . . . . .	38
Figura 16 – Dinâmica de um neurônio <i>Integrate-and-Fire</i> . . . . .	39
Figura 17 – Dinâmica de um neurônio <i>Integrate-and-Fire</i> para período refratário. . . . .	40
Figura 18 – Dinâmica de um neurônio <i>Integrate-and-Fire</i> para as funções cosseno, helicoidal e série de Fourier. . . . .	41

## LISTA DE ABREVIATURAS E SIGLAS

BNCC	Base Nacional Comum Curricular
DH-LIF	Modelo Integra-e-Dispara com Vazamento e Heterogeneidade Dendrítica ( <i>Dendritic Heterogeneity Leaky Integrate-and-Fire</i> )
DH-SNN	Rede Neural de Disparo com Heterogeneidade Dendrítica Temporal ( <i>Spiking Neural Networks with Temporal Dendritic Heterogeneity</i> )
DH-SFNN	Rede Neural Feedforward com Heterogeneidade Dendrítica Temporal ( <i>Dendritic Heterogeneous Spiking Feedforward Neural Network</i> )
DH-SRNN	Rede Neural Recorrente com Heterogeneidade Dendrítica Temporal ( <i>Dendritic Heterogeneous Spiking Recurrent Neural Network</i> )
DMS	Tarefa de Correspondência com Atraso ao Estímulo ( <i>Delayed Match to Sample</i> )
EEG	Eletroencefalograma
ISI	Intervalo entre Disparos ( <i>Inter-Spike Interval</i> )
LIF	Modelo Integra-e-Dispara com Vazamento ( <i>Leaky Integrate-and-Fire</i> )
LTD	Depressão de Longa Duração ( <i>Long-Term Depression</i> )
LTP	Potenciação de Longa Duração ( <i>Long-Term Potentiation</i> )
PBL	Aprendizagem Baseada em Problemas ( <i>Problem-Based Learning</i> )
PhET	<i>Project for Education in Physics and Technology</i>
RC	Circuito Resistor-Capacitor
RNN	Rede Neural Recorrente ( <i>Recurrent Neural Network</i> )
RSNN	Rede Neural Recorrente Esparsa com Disparos ( <i>Recurrent Sparse Spiking Neural Network</i> )
SNC	Sistema Nervoso Central
SNNs	Redes Neurais de Disparo ( <i>Spiking Neural Networks</i> )
TTFS	Tempo até o Primeiro Disparo ( <i>Time-To-First-Spike</i> )

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO . . . . .</b>	<b>13</b>
<b>2</b>	<b>REDES NEURAIS . . . . .</b>	<b>18</b>
<b>2.1</b>	<b>Dinâmica de Memória . . . . .</b>	<b>18</b>
<b>2.2</b>	<b>Sinapse na Formação de Pensamentos . . . . .</b>	<b>25</b>
<b>2.3</b>	<b>Cluster Sináptico e a Formação de Memória de Longo Prazo . . . . .</b>	<b>28</b>
<b>3</b>	<b>METODOLOGIA . . . . .</b>	<b>33</b>
<b>4</b>	<b>DISCUSSÕES E RESULTADOS . . . . .</b>	<b>36</b>
<b>5</b>	<b>IMPLICAÇÕES PEDAGÓGICAS DA DINÂMICA DE MEMÓRIA PARA O ENSINO DE FÍSICA NA EDUCAÇÃO BÁSICA . . . . .</b>	<b>43</b>
<b>6</b>	<b>CONCLUSÃO . . . . .</b>	<b>46</b>
	<b>REFERÊNCIAS . . . . .</b>	<b>48</b>
	<b>ANEXO A - DEMONSTRAÇÃO DO MÉTODO DO FATOR INTE- GRANTE . . . . .</b>	<b>53</b>
	<b>ANEXO B - DEDUÇÃO DAS EQUAÇÕES DE MODELAGEM DA COR- RENTE DENDRÍTICA COM DISCRETIZAÇÃO TEMPORAL . . . . .</b>	<b>55</b>

## 1 INTRODUÇÃO

A dinâmica de memória pode ser compreendida como o conjunto de processos neurobiológicos e biofísicos responsáveis pela codificação, retenção e evocação de informações no sistema nervoso. Este conceito abrange a ideia de que a memória não é um elemento fixo, mas sim um processo dinâmico e contínuo, dependente da atividade funcional das redes neurais e na capacidade dessas redes de se modificar com base nas experiências vividas (Bear *et al.*, 2015).

No âmbito da neurociência, a memória surge das interações complexas entre populações de neurônios interconectados que, através de sinapses químicas e elétricas, ajustam a força de suas conexões com base na experiência. Esse ajuste é promovido principalmente pela plasticidade sináptica, que se manifesta em processos como a potenciação de longa duração (*Long-Term Potentiation* - LTP) e a depressão de longa duração (*Long-Term Depression* - LTD), fenômenos considerados pilares fundamentais para a formação da memória e da aprendizagem (Caporale; Dan, 2008).

A dinâmica da memória abrange, portanto, tanto a atividade elétrica transitória das redes neurais, responsável pela manutenção temporária de informações na memória de curto prazo e na memória de trabalho, quanto as modificações estruturais mais duradouras nas conexões sinápticas que sustentam a formação da memória de longo prazo (Mongillo *et al.*, 2008).

Modelos teóricos e computacionais contemporâneos, como demonstram Subramoney *et al.* (2024), indicam que a dinâmica de memória pode também ser explicada a partir de estados transitórios das redes neuronais (Bellec *et al.*, 2018; Salaj *et al.*, 2021; Zador, 2019). Esses estados permitem o processamento e o armazenamento temporário de informações mesmo sem alterações sinápticas imediatas (Ioannides *et al.*, 2022; Nessler *et al.*, 2013). Nesse contexto, mecanismos como a adaptação da frequência de disparo conferem aos neurônios a capacidade de ajustar temporariamente sua excitabilidade, modulando a forma como processam as informações.

Além disso, conforme destacado por Stanojevic *et al.* (2024), a dinâmica temporal dos disparos neuronais pode ser explorada em arquiteturas profundas de redes neurais, como nas redes *time-to-first-spike* (TTFS), para otimizar a codificação da informação e reduzir o consumo energético. Esses modelos reforçam a concepção de que a dinâmica de memória resulta não apenas de modificações estruturais, mas também de padrões temporais e funcionais da atividade neural (Zhou *et al.*, 2024; Sakemi *et al.*, 2023; Wang *et al.*, 2024).

Em síntese, a dinâmica de memória é um processo multifatorial que integra a atividade elétrica transitória das redes neurais e a plasticidade sináptica. Esses elementos interagem continuamente para possibilitar o armazenamento e a recuperação eficiente de informações,

sustentando, assim, a aprendizagem e a adaptação ao ambiente. A relação entre a formação da memória e os mecanismos de treino cerebral é estreita. Diante disso, abordaremos a dinâmica do treino cerebral como ferramenta essencial para a formação otimizada do pensamento (Kandel *et al.*, 2014).

A formação do pensamento é um fenômeno complexo que resulta da interação entre múltiplos processos neurobiológicos, estruturais e funcionais que ocorrem no cérebro humano. Esses processos são mediados por mecanismos de processamento e adaptação das redes neurais, que podem ser compreendidos como fatores mecânicos de treino cerebral. Esses fatores fundamentam-se em princípios eletrofisiológicos e sinápticos e constituem a base material e funcional para o desenvolvimento das capacidades cognitivas superiores, como a linguagem, o raciocínio abstrato e a tomada de decisão (Miller; Cohen, 2001).

De acordo com Bear *et al.* (2015), a base física da formação do pensamento reside na atividade sináptica entre os neurônios, cuja comunicação ocorre principalmente por impulsos elétricos, denominados potenciais de ação, seguidos pela liberação de neurotransmissores nas sinapses. A modulação dessa comunicação é essencial para o processo de aprendizado e para a formação de novos padrões de pensamento. Um dos principais fatores mecânicos nesse contexto é a plasticidade sináptica, definida como a capacidade de fortalecimento ou enfraquecimento das conexões sinápticas em resposta à atividade neural.

Entre os mecanismos de plasticidade mais estudados destacam-se a LTP e a LTD. A LTP refere-se ao aumento sustentado da eficácia sináptica após estimulação de alta frequência, enquanto a LTD consiste na redução dessa eficácia após padrões específicos de estimulação, geralmente de baixa frequência (Bear *et al.*, 2015). Esses mecanismos são fundamentais para o ajuste das redes neurais durante a aprendizagem e para a formação estável de traços de memória, que constituem a base do pensamento.

Além da plasticidade sináptica, a dinâmica dos padrões de disparo neuronal, também chamada de atividade de *spiking*, desempenha um papel central na formação e treino das redes cerebrais. Estudos recentes indicam que redes neurais podem realizar processos de aprendizagem mesmo com baixos índices de plasticidade sináptica, utilizando a variabilidade temporal dos disparos neuronais como mecanismo de codificação e ajuste funcional (Subramoney *et al.*, 2024; Stanojevic *et al.*, 2024; Perich *et al.*, 2018; Meng *et al.*, 2022). Em especial, Subramoney *et al.* (2024) propõem que o ajuste dinâmico do estado de ativação dos neurônios, mesmo sem alterações estruturais nas sinapses, é suficiente para promover um aprendizado eficiente, desde que a rede esteja adequadamente configurada e operando em um regime apropriado de temporização dos *spikes* (Bellec *et al.*, 2018; Salaj *et al.*, 2021).

De forma complementar, Stanojevic *et al.* (2024) demonstraram que redes neurais profundas compostas por neurônios que disparam com frequência extremamente baixa, cerca

de 0,3 *spike* por neurônio, podem alcançar desempenho computacional elevado. Isso evidencia que a eficiência energética e a precisão temporal são fatores mecânicos determinantes no treinamento cerebral. Essa economia no número de disparos contribui para otimizar o funcionamento cerebral, reduzindo o consumo de energia sem comprometer a complexidade do processamento, o que é essencial para a sustentação da atividade cognitiva humana (Zhou *et al.*, 2024; Meng *et al.*, 2022; Wang *et al.*, 2024; Sakemi *et al.*, 2023).

Outro fator mecânico essencial ao treino cerebral é a organização estrutural das redes neurais. Segundo Bear *et al.* (2015), o cérebro humano é constituído por circuitos interconectados que apresentam topologias específicas. Os tipos de organização entre neurônios incluem: conexões *feedforward*, que transmitem informações em uma única direção, das camadas sensoriais para as mais complexas; conexões *feedback*, que retornam sinais de áreas mais avançadas para as iniciais, contribuindo para o controle e a previsão; e conexões laterais, que promovem a comunicação entre neurônios do mesmo nível, favorecendo o refinamento, a integração e a segregação de informações. A arquitetura dessas redes determina como as informações são processadas, armazenadas e recuperadas, influenciando diretamente a formação de pensamentos complexos (Bassett; Sporns, 2017).

A formação do pensamento ocorre, portanto, por meio de um processo dinâmico e contínuo, caracterizado pela integração sináptica de múltiplos sinais nervosos recebidos de outras regiões do corpo ou do próprio cérebro (sinais aferentes), seguida pela propagação de impulsos elétricos ao longo das redes neuronais. Inicialmente, estímulos sensoriais ou internos provocam alterações no potencial de membrana dos neurônios pós-sinápticos. Quando essas alterações atingem um limiar específico, ocorre a geração de um potencial de ação, que se propaga pelo axônio até alcançar as sinapses, desencadeando a liberação de neurotransmissores. Esse processo estimula outros neurônios, formando cadeias complexas de ativação neural (Oliveira, 2020).

Com a repetição dessas cadeias, padrões específicos de ativação tornam-se mais estáveis e eficientes, fenômeno que está intimamente ligado à plasticidade sináptica e à homeostase neural (isto é, o equilíbrio interno do sistema nervoso, que mantém estáveis a atividade e a eficiência das redes neurais mesmo diante de mudanças). Além disso, estudos em neurociência computacional indicam que a sincronização entre diferentes grupos neuronais, bem como as oscilações rítmicas na atividade elétrica cerebral, são fundamentais para a integração de informações provenientes de múltiplas áreas corticais, que são as diferentes regiões do córtex cerebral responsáveis por funções como percepção, linguagem e raciocínio, culminando na emergência do pensamento consciente (Maass, 2016).

Em síntese, os fatores mecânicos que sustentam o treino cerebral e possibilitam a formação do pensamento incluem: a modulação da força sináptica por mecanismos plásticos;

a regulação precisa dos padrões de disparo neuronal; a organização estrutural e topológica das redes neurais; e a coordenação rítmica e temporal da atividade elétrica cerebral. Esses processos, atuando de forma integrada, permitem que o cérebro codifique, armazene e recupere informações de maneira eficiente, possibilitando a elaboração de pensamentos cada vez mais complexos e adaptativos (Bassi *et al.*, 2019; Borges *et al.*, 2017; Shota *et al.*, 2016). Neste contexto, se faz necessário entendermos a formação da dinâmica de memória de longo prazo.

A formação da memória de longo prazo depende da organização funcional e estrutural de agrupamentos sinápticos, ou seja, de *clusters* de conexões que se estabilizam e sustentam padrões recorrentes e coordenados de atividade neural. Esses agrupamentos são caracterizados por propriedades específicas: densidade elevada de conexões, sincronização na atividade elétrica, estabilidade temporal e capacidade de indução e manutenção de plasticidade sináptica (Finnie; Nader, 2012).

A memória duradoura resulta de alterações estáveis na força das conexões sinápticas, principalmente através de processos como a LTP e a LTD (Bear *et al.*, 2015). Esses mecanismos ocorrem preferencialmente em agrupamentos coordenados de sinapses, os *clusters* sinápticos, que se organizam funcionalmente para reforçar determinados circuitos e inibir outros, promovendo a seletividade e a eficiência na consolidação de memórias.

A sincronização de *clusters* neuronais contribui para a resiliência ao ruído e para a manutenção de padrões específicos de ativação em redes complexas (Lodi *et al.*, 2020). A identificação de tais agrupamentos, por meio de técnicas matemáticas e simulações computacionais, revela que essas estruturas são capazes de suportar dinamicamente estados persistentes, condição considerada essencial para a retenção e consolidação da memória de longo prazo.

A organização hierárquica e modular das redes neuronais está associada à capacidade do cérebro de processar informações de forma rápida e robusta (Maass, 2016). A formação de memórias, nesse contexto, depende da presença de sub-redes ou agrupamentos estruturados que operam de forma sincronizada e coesa. *Clusters* eficazes para a memória de longo prazo devem, portanto, apresentar uma conectividade interna elevada que possibilita múltiplos caminhos de ativação, sincronização temporal que garante a coativação coordenada, estabilidade estrutural e funcional frente a perturbações e plasticidade modulada que permite ajustar a força das conexões conforme a experiência.

Estudos demonstraram que, mesmo sem depender diretamente de processos tradicionais de plasticidade sináptica, as estruturas organizadas de agrupamentos neuronais podem suportar aprendizado rápido e a retenção de padrões complexos (Subramoney *et al.*, 2024; Brea; Gerstner, 2016; Salaj *et al.*, 2021). Entretanto, para que esses padrões sejam convertidos em memória de longo prazo, torna-se necessária uma posterior estabilização das conexões, processo que, na biologia, ocorre por meio de mudanças moleculares e estruturais nas sinapses.

Também foi evidenciado que, mesmo com baixas taxas de disparo, característica relacionada à eficiência metabólica do cérebro, a estrutura e a organização dos *clusters* permitem a generalização e o armazenamento eficiente de informações (Stanojevic *et al.*, 2024; Meng *et al.*, 2022; Zhou *et al.*, 2024; Sakemi *et al.*, 2023). Isso evidencia que a estrutura e a sincronização de agrupamentos neuronais são mais determinantes para a memória do que a intensidade da atividade elétrica isolada.

Além disso, as oscilações neurais sincronizadas são fundamentais na coordenação da atividade de grupos de neurônios (Buzsaki; Draguhn, 2004). Esses padrões oscilatórios favorecem a sincronização funcional de *clusters*, condição essencial para a consolidação das memórias de longo prazo. A formação de tais agrupamentos sincronizados é regulada por processos de homeostase sináptica e sustentada por mecanismos moleculares, como a síntese de novas proteínas, que estabilizam as alterações estruturais necessárias para a manutenção da memória (Tonegawa *et al.*, 2018).

Os agrupamentos de *clusters* sinápticos que favorecem a formação de memória de longo prazo são, portanto, aqueles que se organizam em estruturas densamente conectadas, sincronizadas e estáveis, capazes de sustentar padrões recorrentes de ativação e de serem modificados por mecanismos plásticos. A sincronização desses *clusters* cria as condições dinâmicas para que circuitos neurais possam manter estados persistentes, enquanto os mecanismos de plasticidade moldam e consolidam tais padrões, garantindo a persistência e a robustez das memórias ao longo do tempo (Kastellakis *et al.*, 2015).

Este trabalho está estruturado da seguinte forma: a Introdução apresenta a relevância da dinâmica cerebral no processo de aprendizagem, destacando os fundamentos neurobiológicos da formação de memórias e pensamentos. O Capítulo 2 aprofunda-se na base teórica, abordando as redes neurais, a dinâmica da memória, o papel das sinapses na formação do pensamento, os *clusters* sinápticos e sua relação com a memória de longo prazo. O Capítulo 3 descreve a metodologia adotada para analisar a dinâmica neural por meio de equações diferenciais aplicadas ao potencial de ação. No Capítulo 4, são apresentados e discutidos os resultados obtidos a partir do modelo proposto. O Capítulo 5 trata das implicações pedagógicas da dinâmica da memória para o ensino de Física na educação básica. Por fim, o Capítulo 6 apresenta as conclusões do estudo, destacando as contribuições da pesquisa.

## 2 REDES NEURAIS

### 2.1 Dinâmica de Memória

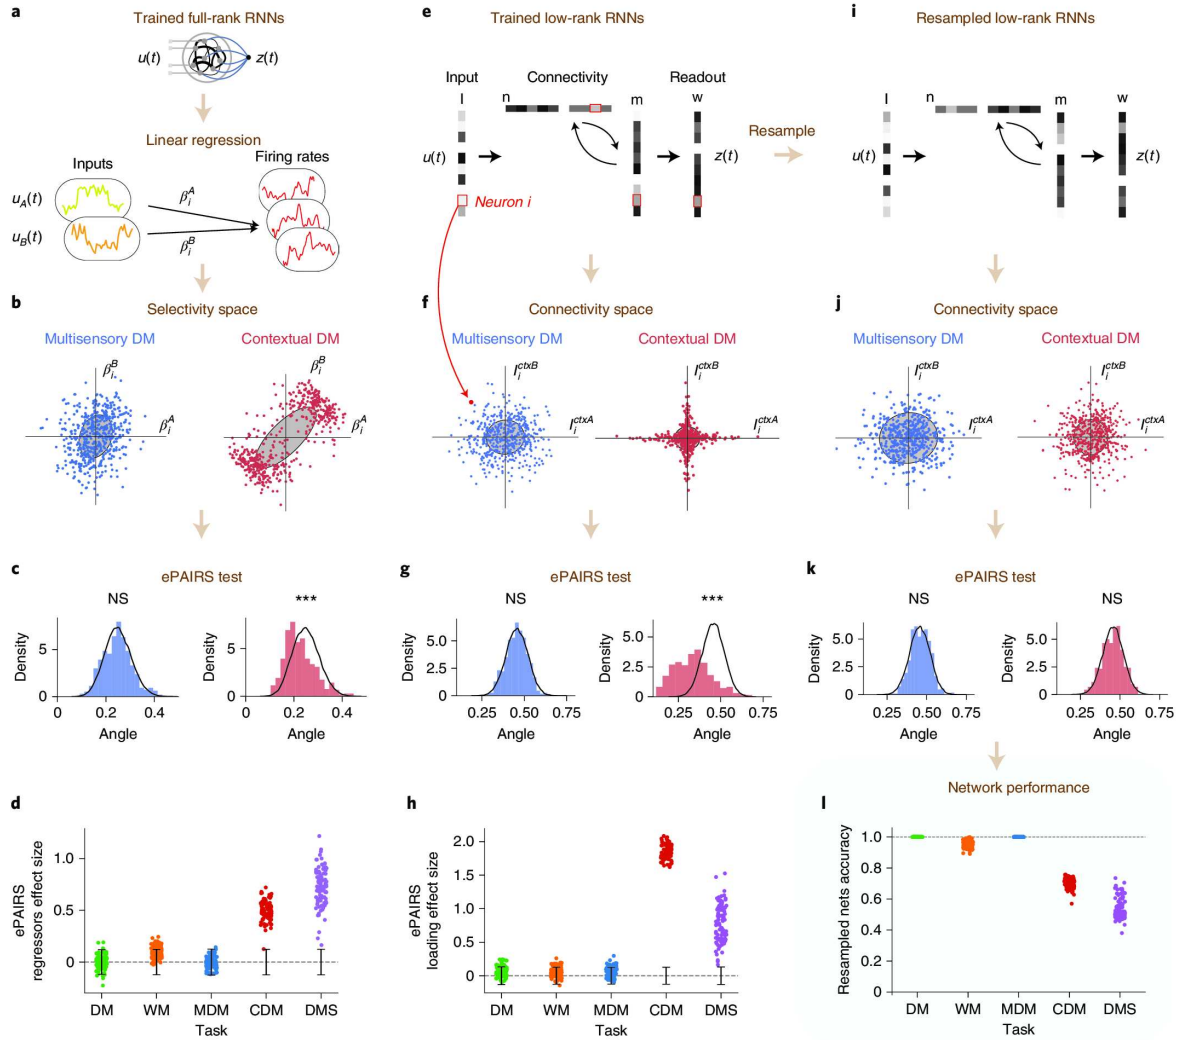
O cérebro humano é composto por bilhões de células chamadas neurônios, que se conectam, formando extensas redes capazes de processar informações, aprender e gerar comportamentos complexos. Essas redes, conhecidas como redes neurais biológicas, são estruturas compostas por unidades fundamentais chamadas neurônios, que se conectam entre si por meio de sinapses. Essas conexões formam uma malha complexa em que os neurônios funcionam como os sítios (ou vértices) da rede, e os sinais elétricos e químicos que trafegam entre eles representam as arestas (ou conexões). A configuração dessas conexões determina como a informação é propagada e processada no cérebro, sendo, portanto, um elemento-chave para o entendimento de processos cognitivos como a memória, o aprendizado e a tomada de decisões.

A dinâmica da memória, quando observada a partir do funcionamento das redes neurais, revela-se como um processo emergente da interação entre unidades neuronais conectadas em padrões complexos e adaptativos. As memórias não são armazenadas em locais fixos e imutáveis, mas surgem da atividade coletiva e coordenada dessas redes, cuja configuração estrutural e funcional se transforma ao longo do tempo em resposta a estímulos internos e externos (Dubreuil *et al.*, 2022).

A compreensão da dinâmica da memória é essencial para entender os mecanismos pelos quais o cérebro codifica, retém e recupera informações. Ao estudar as redes neurais envolvidas nesse processo, é possível não apenas descrever os mecanismos neurobiológicos subjacentes, mas também modelar computacionalmente tais fenômenos com aplicações em inteligência artificial, diagnóstico de doenças neurológicas e tecnologias educacionais baseadas em neurociência (Runfola *et al.*, 2025; Zhang *et al.*, 2025).

A formação de uma rede neural funcional envolve a organização de populações de neurônios em subgrupos interligados com padrões de conectividade específicos. Segundo Dubreuil *et al.* (2022), a maneira como essas subpopulações são estruturadas tem um impacto direto sobre as capacidades computacionais da rede, especialmente em tarefas que exigem flexibilidade cognitiva e reconfiguração de entradas e saídas (Béna; Goodman, 2025). Essa estrutura funcional não é estática, mas se adapta conforme a tarefa ou o contexto, o que reflete a natureza plástica da memória. A figura 1 apresenta uma visão detalhada dessa organização, ilustrando as diferentes configurações de subpopulações em redes neurais treinadas para diversas tarefas cognitivas.

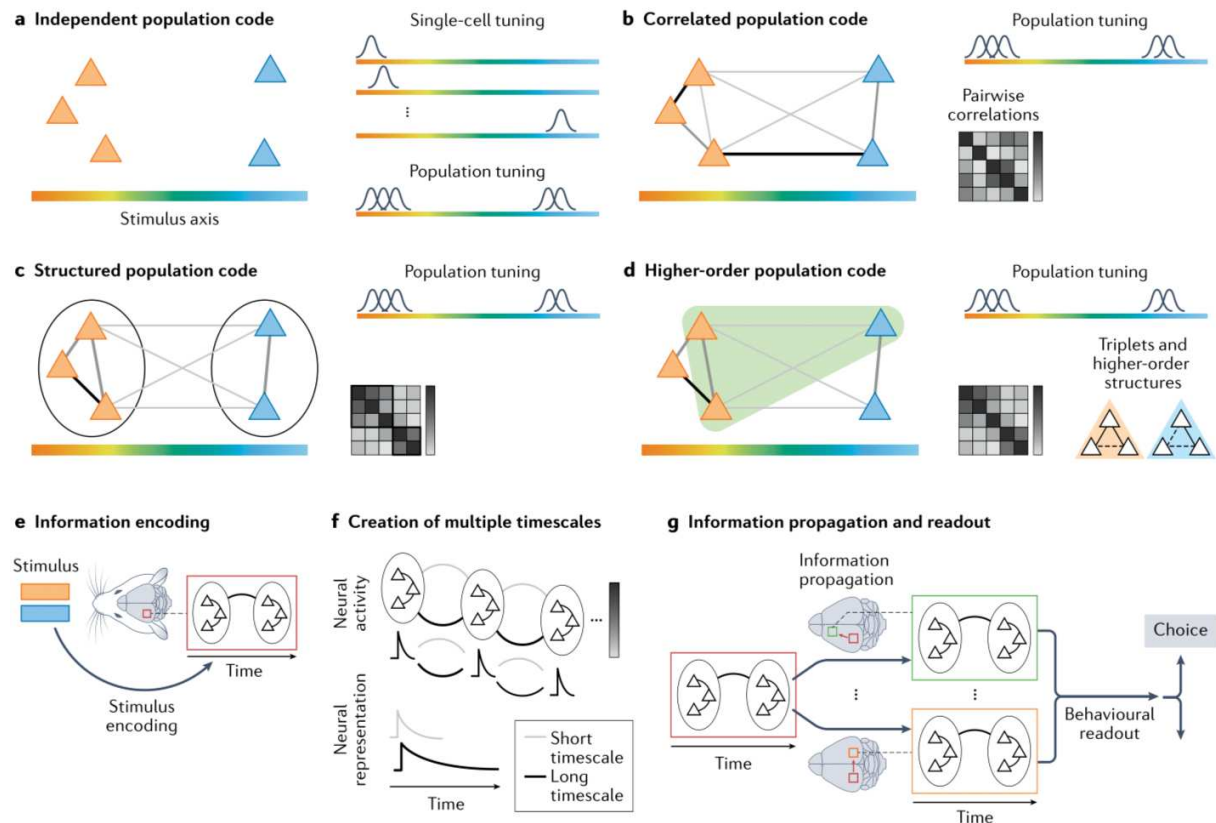
Figura 1: Representação da estrutura de subpopulações neuronais em redes neurais recorrentes treinadas para diferentes tarefas cognitivas. A figura mostra que, mesmo quando os estímulos de entrada são semelhantes, redes treinadas para tarefas distintas organizam seus neurônios de forma diferenciada, evidenciando padrões específicos de seletividade e conectividade. Esses padrões formam estruturas internas que não ocorrem ao acaso, refletindo a adaptação funcional da rede às exigências de cada tarefa.



Fonte: Dubreuil *et al.* (2022).

Essa organização estruturada das redes também depende da natureza das correlações entre os disparos neuronais. Panzeri *et al.* (2022) demonstram que correlações estruturadas entre neurônios com propriedades similares são fundamentais para a codificação eficiente da informação. Redes com correlações bem organizadas conseguem representar estímulos com maior fidelidade e sustentar esses padrões de atividade por períodos prolongados, o que é essencial para a retenção de memórias de curto e médio prazo (Buzsáki; Mizuseki, 2014). A figura 2 ilustra esquematicamente diferentes padrões de correlação neural e sua relação com a capacidade de representação e processamento cognitivo da informação.

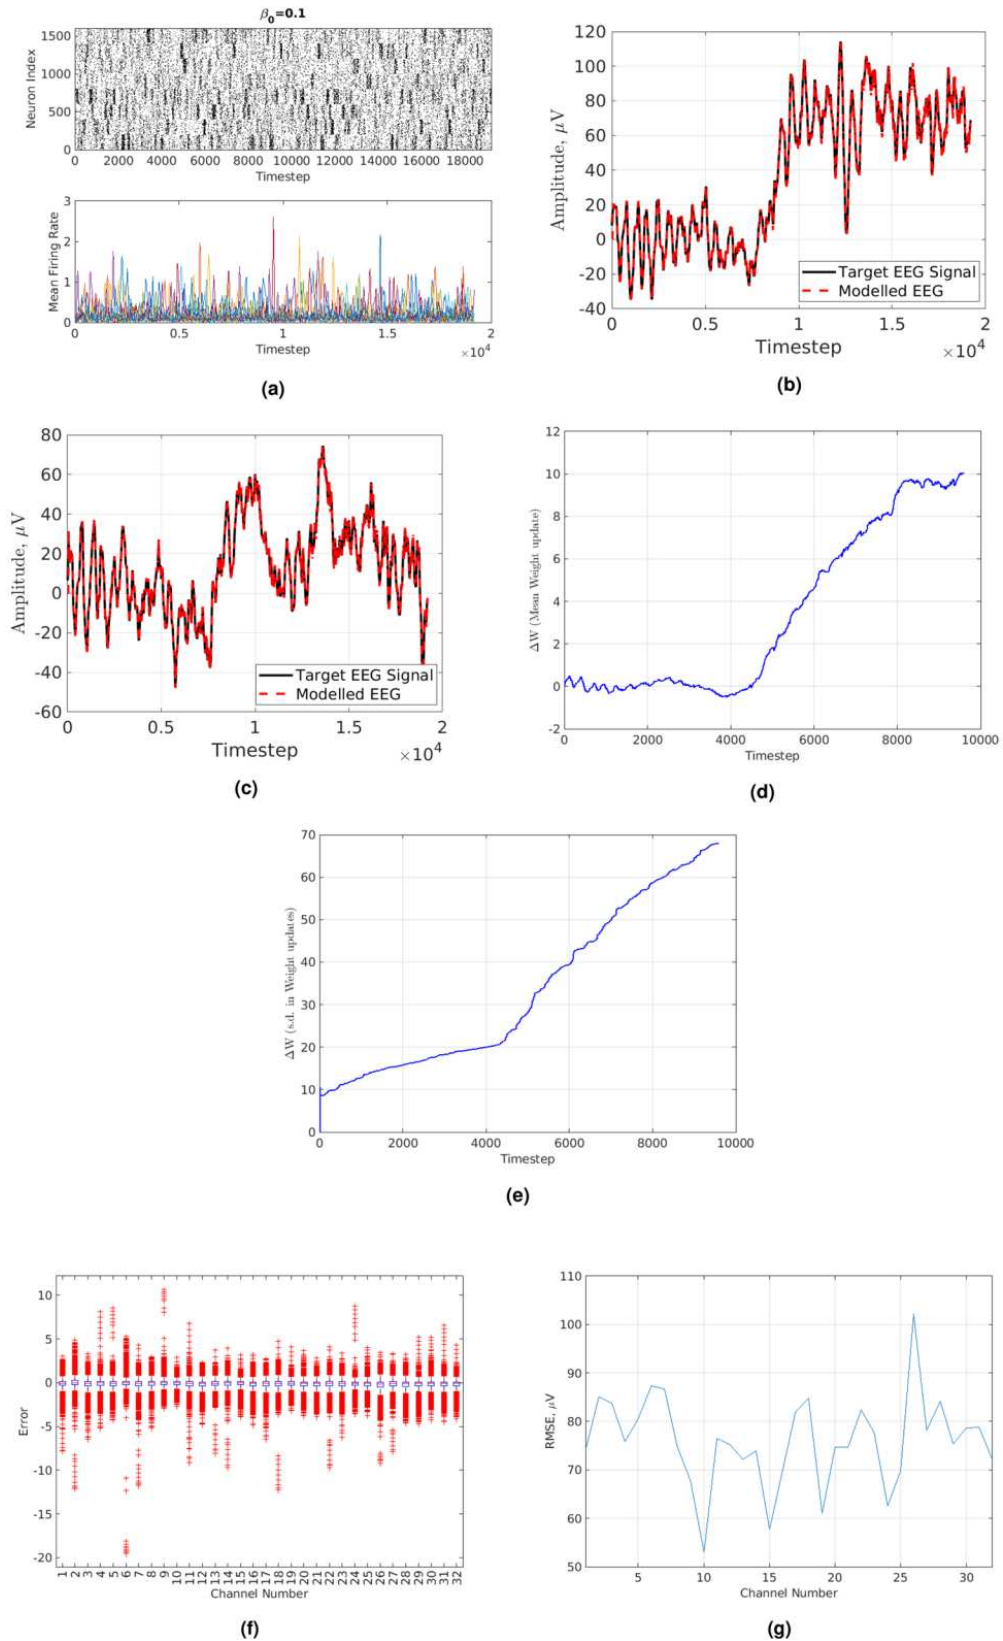
Figura 2: Esquema ilustrativo de diferentes tipos de códigos populacionais neurais e suas possíveis funções cognitivas. A figura compara padrões de disparo com e sem correlação entre os neurônios e associa cada tipo de estrutura a modos distintos de processamento de informação. Códigos com correlações organizadas entre neurônios com propriedades similares tendem a favorecer a fidelidade representacional e o armazenamento transitório da informação, enquanto padrões mais ruidosos podem estar associados à flexibilidade cognitiva ou ao processamento sensorial rápido.



Fonte: Panzeri *et al.* (2022).

A dinâmica temporal da atividade neural também é um componente essencial do funcionamento da memória. Em redes neurais recorrentes com neurônios do tipo *spiking*, como as utilizadas por Ioannides *et al.* (2022), a memória pode ser sustentada por padrões recorrentes de atividade elétrica que simulam o comportamento de regiões cerebrais reais, como observado em sinais de eletroencefalograma (EEG). Esses padrões, uma vez aprendidos, são capazes de reproduzir dinamicamente informações sem necessidade de alterações estruturais imediatas na conectividade sináptica. A figura 3 compara sinais reais de EEG com as saídas geradas por uma rede recorrente treinada, destacando a similaridade temporal entre as dinâmicas biológicas e simuladas.

Figura 3: Comparação entre sinais reais de EEG e as saídas geradas por uma rede neural recorrente com disparo treinada pelo algoritmo *modified-FORCE*. Os traçados em azul representam os sinais de EEG obtidos experimentalmente, enquanto os traçados em vermelho correspondem às respostas da rede simulada. A figura evidencia a semelhança temporal entre os padrões reais e simulados, sugerindo que a rede foi capaz de aprender as dinâmicas temporais complexas presentes nos sinais biológicos.

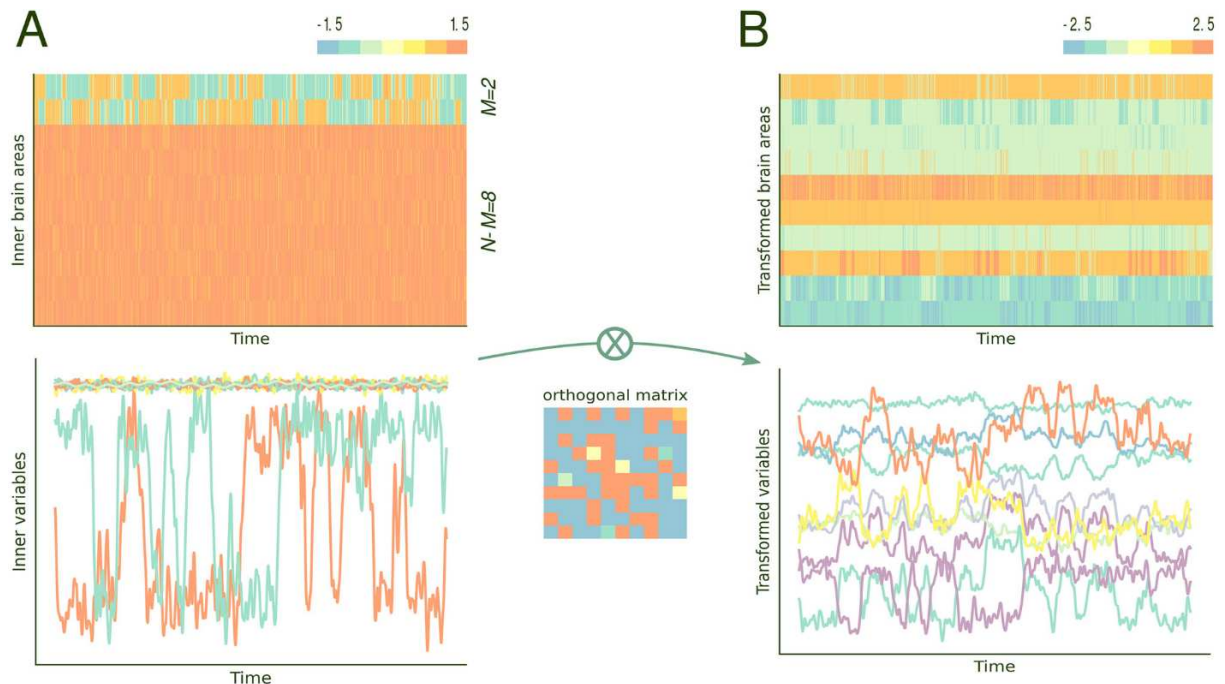


Fonte: Ioannides *et al.* (2022).

Kim e Sejnowski (2021) complementam essa visão ao mostrar que a estabilidade temporal exigida por memórias de trabalho está relacionada à presença de microcircuitos inibitórios fortes dentro das redes. Esses microcircuitos permitem o controle da excitação global da rede e evitam a degradação rápida dos sinais, sustentando a informação mesmo na ausência de estímulo externo (Grosmark; Buzsáki, 2016).

Um aspecto complementar é a capacidade de representação em baixa dimensionalidade. Conforme argumentam Runfola *et al.* (2025), mesmo com uma dinâmica altamente complexa e multidimensional, os estados funcionais das redes tendem a se projetar em trajetórias de baixa dimensão, chamadas de *manifolds*. Essas regiões no espaço de estados representam configurações estáveis da rede que sustentam memórias temporárias sem necessidade de intervenção sináptica duradoura. A figura 4 ilustra esse princípio ao mostrar como uma rede simulada composta por múltiplos nós interconectados apresenta dinâmicas oscilatórias e biestáveis que, após uma transformação ortogonal, ocultam sua estrutura original, revelando a importância das representações internas comprimidas.

Figura 4: Visualização de trajetórias neurais simuladas em um sistema composto por dez nós acoplados. O painel A exibe as séries temporais dos dez nós simulados (acima), seguidas da mesma informação em forma de mapa de calor (abaixo), facilitando a identificação dos padrões dinâmicos. Nessa configuração, os dois nós principais, que compõem o sistema biestável, alternam entre estados de ativação alta e baixa, enquanto os demais nós oscilam ritmicamente em resposta ao estado dominante da rede. O painel B apresenta os mesmos dados após uma transformação ortogonal, que reorganiza a atividade da rede de forma que as dinâmicas originais, como as oscilações e a biestabilidade, tornam-se invisíveis na leitura direta dos sinais dos nós. Essa transformação evidencia como estruturas de baixa dimensionalidade, conhecidas como *manifolds*, podem estar embutidas em redes mais complexas e só se tornam acessíveis por meio de representações projetadas.



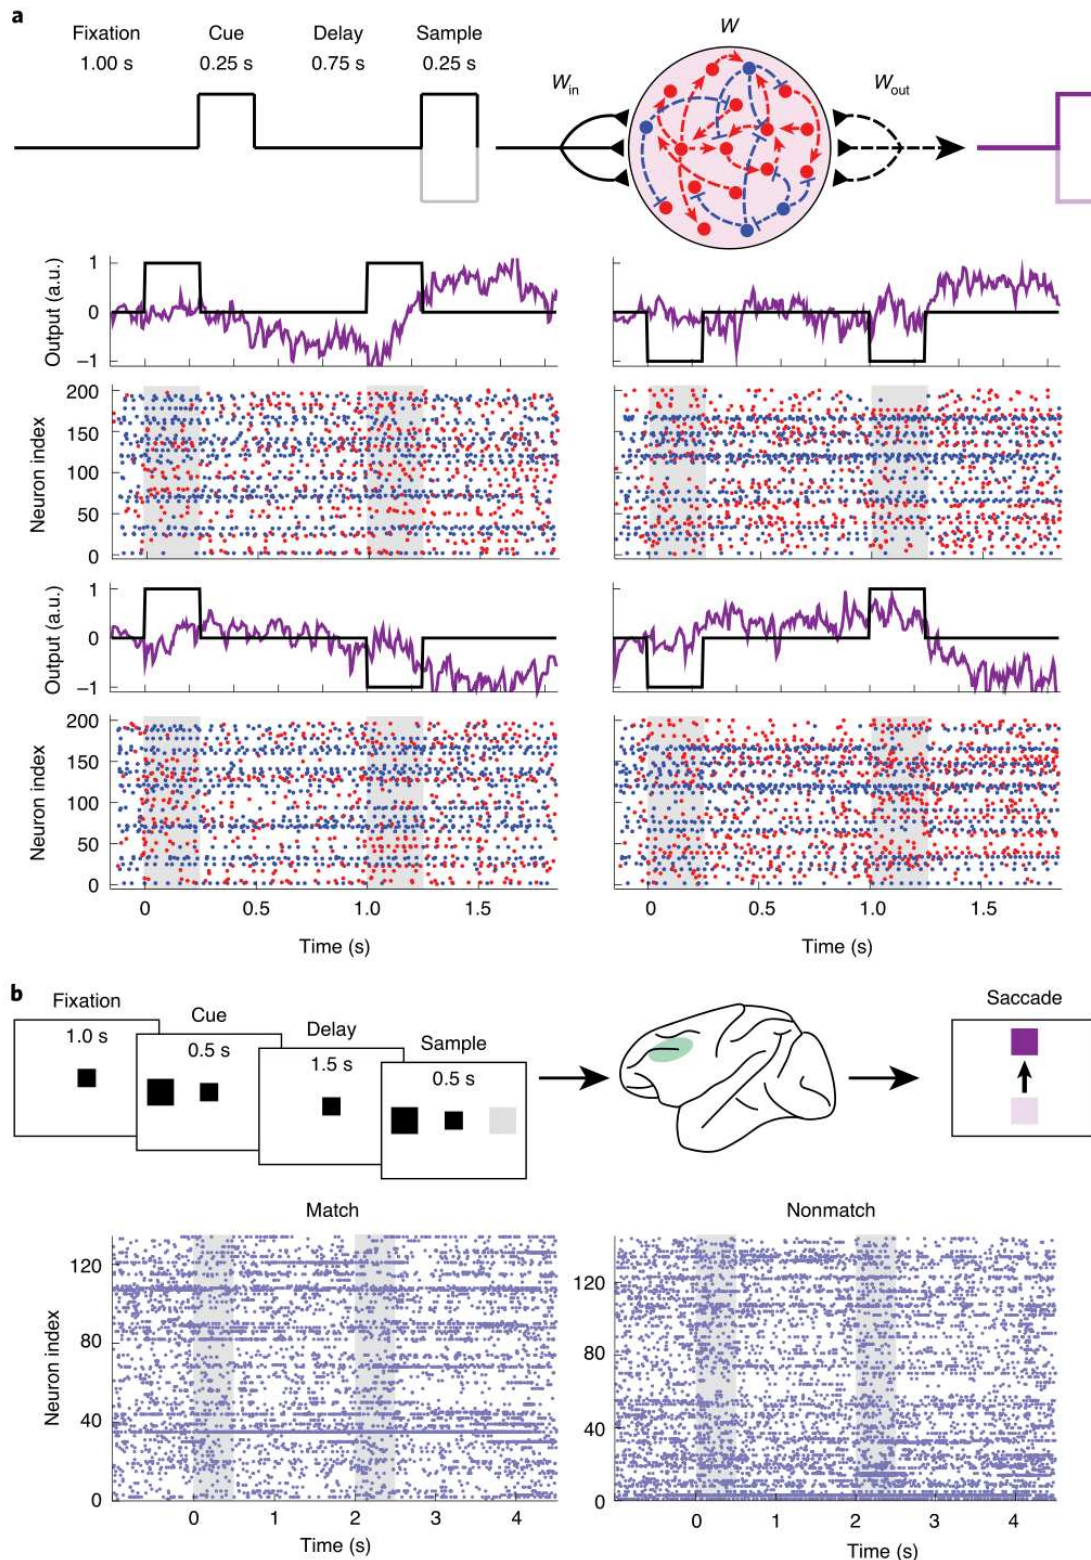
Fonte: Adaptado de Runfola *et al.* (2025).

A arquitetura dessas redes também pode incorporar modelagens matemáticas mais

precisas, como demonstrado por Hasani *et al.* (2022), que propõem modelos em tempo contínuo com solução analítica aproximada. Esses modelos permitem representar explicitamente a passagem do tempo, o que é particularmente útil para simular a retenção transitória de informações característica da memória de curto prazo. O tempo deixa de ser um parâmetro externo e passa a integrar a própria dinâmica da rede.

Esses resultados convergem para a compreensão de que a memória é um fenômeno multifacetado, sustentado tanto por mudanças estruturais duradouras quanto por padrões temporais transitórios (Hasani *et al.*, 2022). A formação, a organização funcional e a dinâmica temporal das redes neurais interagem continuamente para possibilitar a codificação, a retenção e a recuperação eficiente da informação, pilares fundamentais da memória no contexto biológico e computacional. A figura 5, baseada em Kim e Sejnowski (2021), ilustra como esses princípios são aplicados em redes neurais treinadas para tarefas de memória de trabalho.

Figura 5: Representação de um modelo de rede neural recorrente (*Recurrent Neural Network*, RNN) composto por unidades excitatórias (círculos vermelhos) e inibitórias (círculos azuis), treinado para executar a tarefa de *Delayed Match to Sample* (DMS, tarefa de correspondência retardada). No painel à esquerda (a), são apresentadas a estrutura da rede e os sinais de saída produzidos pela RNN treinada, incluindo gráficos dos disparos neuronais durante a janela de estímulo (área sombreada em cinza). O painel à direita (b) mostra dados experimentais obtidos em macacos submetidos à tarefa espacial de DMS, com registros de disparos neuronais no córtex pré-frontal dorsolateral durante tentativas de acerto e erro.




Fonte: Kim e Sejnowski (2021).

## 2.2 Sinapse na Formação de Pensamentos

A formação do pensamento humano emerge da interação dinâmica entre os componentes funcionais do sistema nervoso, especialmente das sinapses. Essas junções entre os neurônios não apenas transmitem informações, mas também modulam a forma como elas são codificadas, armazenadas e evocadas (Bear *et al.*, 2015). É por meio dessa arquitetura plástica e adaptativa que o cérebro consegue transformar estímulos sensoriais e experiências em ideias, raciocínios e decisões. No contexto educacional, compreender esses fundamentos permite desenvolver abordagens de ensino mais eficazes, capazes de alinhar o funcionamento cerebral com estratégias pedagógicas como o uso de jogos e linguagens de programação no ensino de Física.

Um dos mecanismos centrais desse processo é a plasticidade sináptica, que consiste na capacidade de fortalecimento ou enfraquecimento das conexões sinápticas em função da atividade neural. Entre os processos mais estudados estão a LTP e a LTD, que correspondem, respectivamente, ao aumento e à redução da eficácia sináptica ao longo do tempo (Bear *et al.*, 2015). Esses mecanismos, ilustrados na figura 6, são fundamentais para consolidar memórias e estabilizar padrões de pensamento. No campo educacional, jogos que desafiam o raciocínio lógico ou atividades de simulação de fenômenos físicos podem contribuir para acionar e reforçar esses circuitos de memória.

Figura 6: Representação esquemática dos mecanismos de LTP e LTD mediados por diferentes concentrações de cálcio intracelular em uma sinapse do hipocampo. Estímulos de alta frequência favorecem LTP, enquanto estímulos de baixa frequência induzem LTD.




Fonte: Adaptado de Bear *et al.* (2015)

Além da plasticidade, os padrões de disparo dos neurônios também desempenham um papel crucial na codificação da informação. A atividade de *spiking*, caracterizada por picos temporais de ativação neuronal, é fundamental para o funcionamento das redes neurais (Panzeri *et al.*, 2022; Yu *et al.*, 2014). Subramoney *et al.* (2024) demonstraram que redes neurais podem realizar aprendizagem eficiente mesmo com baixa plasticidade sináptica, desde que os disparos ocorram com precisão temporal (Salaj *et al.*, 2021; Bellec *et al.*, 2018; Jin *et al.*, 2018). Esse princípio é evidenciado por modelos de redes que operam com frequência reduzida de picos,

mas que atingem alta performance (Stanojevic *et al.*, 2024; Sakemi *et al.*, 2023). A figura 7 apresenta um desses modelos, que reforça a importância da codificação temporal no desempenho cognitivo.

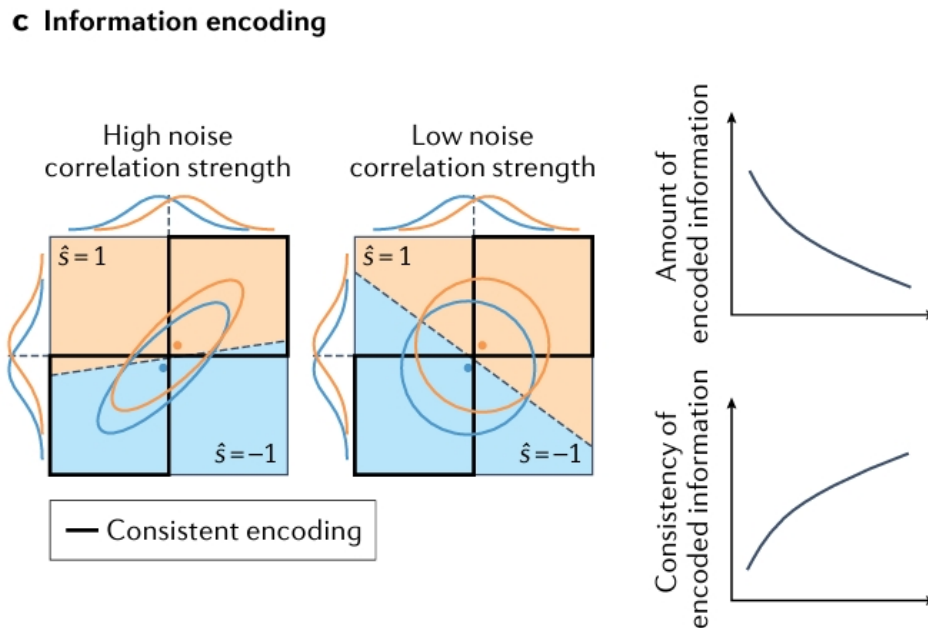
Figura 7: Modelo computacional de rede neural recorrente esparsa (RSNN), no qual a aprendizagem eficiente é obtida com baixa plasticidade sináptica, baseada apenas na sincronização temporal dos disparos neuronais. A imagem mostra a evolução temporal das variáveis internas  $\varphi_1$  e  $\varphi_2$  de dois neurônios durante a execução da tarefa.



Fonte: Adaptado de Subramoney *et al.* (2024)

Essa modulação temporal, somada à organização estrutural das redes neurais, configura o alicerce da formação de pensamentos complexos. Segundo Bear *et al.* (2015), circuitos neurais organizam-se em padrões *feedforward*, *feedback* e laterais, que promovem integração e refinamento das informações processadas. Panzeri *et al.* (2022) complementam essa perspectiva ao apontar que a sincronia funcional entre diferentes regiões neurais é essencial para gerar estados mentais coerentes (Perich *et al.*, 2018). A figura 8 exemplifica como múltiplos grupos de neurônios podem operar de forma coordenada em tarefas cognitivas, o que tem implicações diretas para o ensino de Física, onde múltiplos conceitos precisam ser articulados simultaneamente.

Figura 8: Distribuição de atividade de dois neurônios durante a codificação de um estímulo, destacando a sincronia funcional entre eles. As regiões diagonais evidenciam a consistência da informação, exemplificando como múltiplos grupos de neurônios podem operar de forma coordenada em tarefas cognitivas.



Fonte: Adaptado de Panzeri *et al.* (2022).

No contexto educacional, essas descobertas sugerem que atividades de aprendizagem devem estimular múltiplas dimensões cognitivas ao mesmo tempo. Por exemplo, o uso de linguagens de programação como Python pode ser integrado ao ensino de fenômenos físicos por meio de jogos computacionais, que exigem atenção, memória operacional e abstração lógica. Essas tarefas, além de promoverem engajamento, favorecem o treino de padrões neurais eficientes, otimizando a formação do pensamento científico (Sousa *et al.*, 2019). Hasani *et al.* (2022) destacam que estruturas computacionais bioinspiradas podem modular padrões rítmicos cerebrais, o que reforça a viabilidade de aplicar conceitos de neurociência à prática pedagógica.

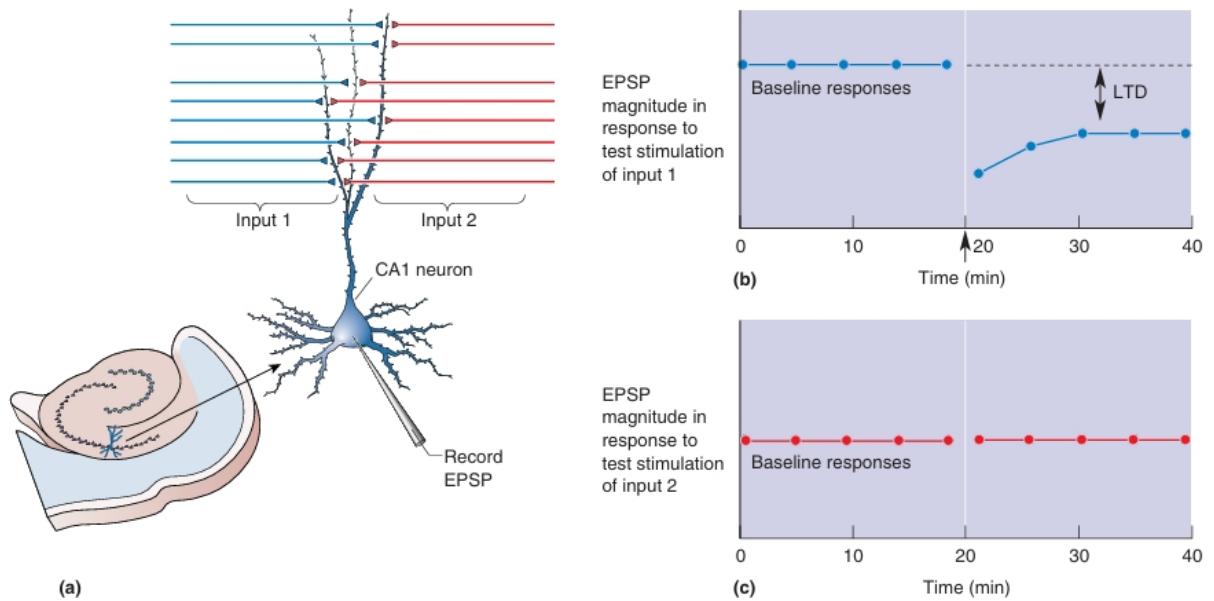
Concluindo, a formação de pensamentos é um processo contínuo que envolve plasticidade sináptica, padrões temporais de disparo, arquitetura neural e sincronização funcional. Compreender esses fundamentos é essencial para desenvolver práticas pedagógicas alinhadas ao funcionamento cerebral. Ao incorporar jogos, simulações e linguagens de programação no ensino de Física, o educador pode não apenas facilitar a aprendizagem, mas também respeitar as bases neurobiológicas da cognição. Essa abordagem torna o processo educativo mais eficiente, integrador e próximo das reais capacidades do cérebro humano.

### 2.3 Cluster Sináptico e a Formação de Memória de Longo Prazo

A consolidação da memória de longo prazo envolve um conjunto complexo de mecanismos moleculares e estruturais que se manifestam nas sinapses neuronais, em especial nos chamados *clusters* sinápticos (Tonegawa *et al.*, 2018; Bear *et al.*, 2015). Esses agrupamentos organizados de sinapses próximas em dendritos de um mesmo neurônio desempenham um papel crucial na estabilidade das representações mnemônicas, isto é, relacionadas à memória, ao longo do tempo (Borges *et al.*, 2017). A formação de tais *clusters* está associada a disparos temporais coordenados entre neurônios, processo que está na base da atividade de *spikes* em redes neurais biológicas e artificiais (Buzsaki; Draguhn, 2004; Ioannides *et al.*, 2022). A atividade em forma de *spike*, ou potencial de ação, caracteriza-se por uma sequência precisa de picos de voltagem que ocorrem em intervalos de tempo altamente regulados (Bear *et al.*, 2015; Debanne; Inglebert, 2023). Esses padrões temporais são responsáveis não apenas pela transmissão da informação entre os neurônios, mas também pela modulação da eficácia sináptica, o que torna possível a aprendizagem e a memória (Subramoney *et al.*, 2024; Kim; Sejnowski, 2021; Brea; Gerstner, 2016).

A plasticidade sináptica é frequentemente descrita por dois mecanismos fundamentais: a LTP e a LTD. A LTP ocorre quando a atividade sináptica repetida, associada a uma despolarização suficiente do neurônio pós-sináptico, resulta em um aumento duradouro da eficácia sináptica. Por outro lado, a LTD representa uma diminuição sustentada da força sináptica, normalmente induzida por padrões de ativação menos intensos ou mal sincronizados. Ambos os mecanismos dependem de alterações intracelulares, como a regulação de cálcio e a ativação de vias enzimáticas, que afetam a expressão de receptores e a arquitetura da espinha dendrítica (Bear *et al.*, 2015; Tonegawa *et al.*, 2018; Borges *et al.*, 2017). Esses processos estão representados esquematicamente na figura 9. Essas alterações moleculares sustentam a capacidade do sistema nervoso de adaptar-se a novos estímulos, facilitando a codificação e a consolidação de memórias (Dubreuil *et al.*, 2022; Kim; Sejnowski, 2021).

Figura 9: Representação esquemática dos mecanismos de LTP e LTD em sinapses do hipocampo. A intensidade do estímulo modula a concentração de cálcio, determinando a direção da plasticidade sináptica.




Fonte: Adaptado de Bear *et al.* (2015).

A organização das sinapses em *clusters* otimiza o processamento neural ao concentrar a atividade sináptica em regiões específicas dos dendritos, o que favorece a eficiência funcional do sistema nervoso. Segundo Makino e Malinow (2011), tais agrupamentos favorecem a ocorrência de sincronizações locais entre sinapses adjacentes, o que aumenta a probabilidade de disparo do neurônio e facilita o armazenamento conjunto de informações relacionadas. Essa arquitetura permite que experiências semelhantes, representadas por padrões de disparo próximos, sejam codificadas de maneira integrada. Como mostra a figura 10, a presença de sinapses coativas dentro de uma mesma região dendrítica favorece a formação de uma memória coesa e resistente à interferência de novos estímulos.

Figura 10: Organização compartimentalizada de sinapses coativas em um dendrito de neurônio cortical, evidenciada por imagem de fluorescência em resposta à estimulação sensorial.

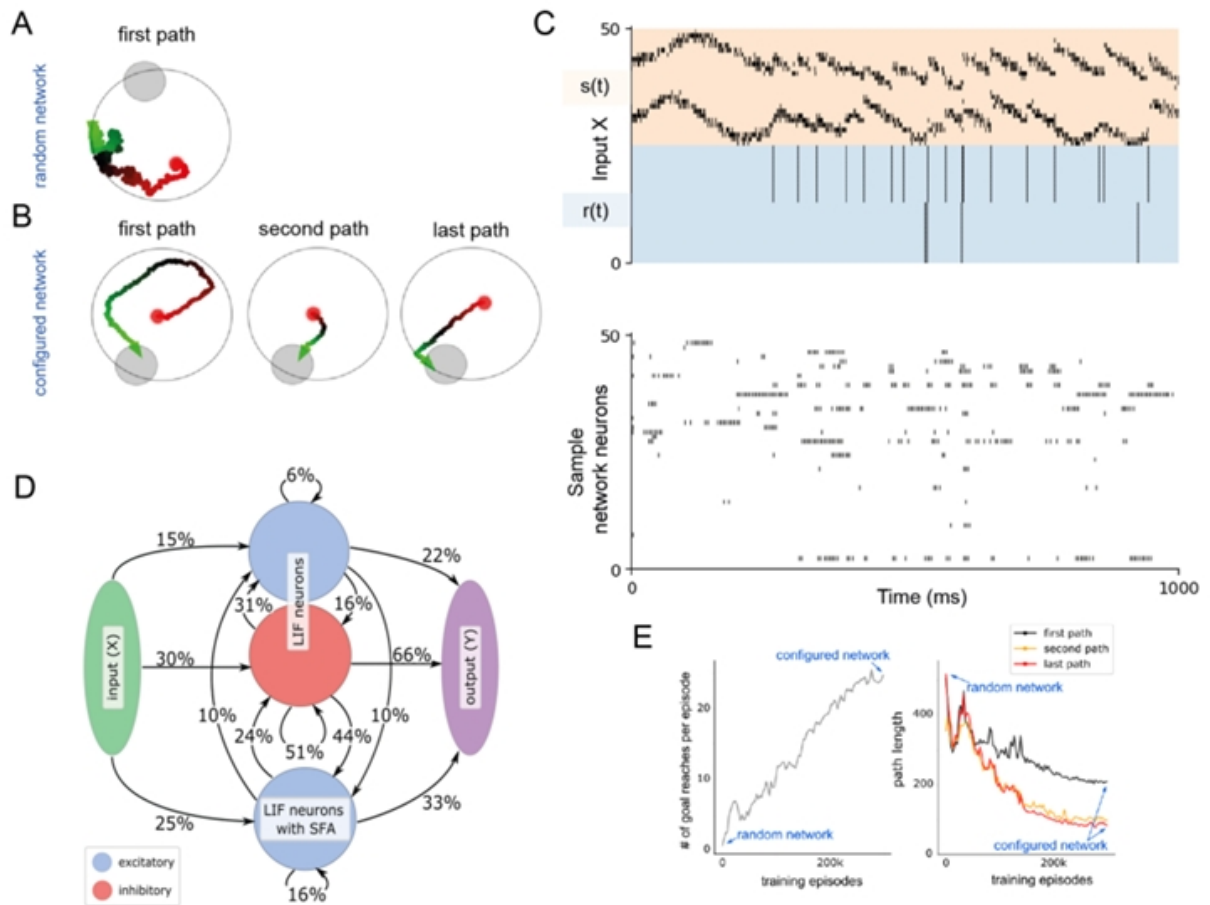
**A** SEP-GluR1 & DsRed from whisker-intact animal



Fonte: Adaptado de Makino e Malinow (2011).

Os *clusters* sinápticos não apenas sustentam a memória de longo prazo, mas também interagem com os padrões de *spikes* temporais que caracterizam a codificação neural. Subramoney *et al.* (2024) demonstraram que redes neurais recorrentes baseadas em *spikes* (RSNNs) podem aprender estratégias eficientes de navegação sem necessidade de plasticidade sináptica durante a execução, graças à otimização das conexões no *loop* externo de aprendizado, conforme ilustrado na figura 11. Essa observação é reforçada por Stanojevic *et al.* (2024), que mostraram que redes com apenas 0.3 *spike* por neurônio por amostra conseguem alcançar alta performance, desde que os eventos de disparo estejam organizados em sequência temporal adequada (Stanojevic *et al.*, 2024; Zhou *et al.*, 2024). Isso sugere que a informação está contida não na quantidade de *spikes*, mas na estrutura temporal em que ocorrem. Esse princípio de codificação baseada em precisão temporal também foi discutido por Zador (2019), Meng *et al.* (2022), que argumentam que o cérebro depende mais de estrutura dinâmica do que de arquitetura estática para representar informações sensoriais complexas.


Figura 11: Aprendizado baseado em recompensa de uma rede neural recorrente baseada em *spikes* (RSNN) sem plasticidade sináptica durante a execução. (A,B) Exemplos de trajetórias de navegação antes e depois do treinamento; (C) Dinâmica da rede durante o comportamento; (D) Arquitetura da RSNN; (E) Curvas de aprendizado mostrando variação no número de metas atingidas e no comprimento dos caminhos.



Fonte: Subramoney *et al.* (2024).

No contexto biológico, os *clusters* sinápticos também contribuem para a formação dos chamados engramas de memória, definidos como conjuntos de neurônios que participam da codificação de uma lembrança específica. Tonegawa *et al.* (2018) mostraram que tais engramas envolvem sinapses reforçadas e organizadas em padrões estruturais específicos, frequentemente associados a regiões como o hipocampo e o córtex pré-frontal. Esses circuitos ativam-se de forma recorrente durante a rememoração, o que corrobora a hipótese de que a memória de longo prazo depende não apenas da presença de sinapses fortalecidas, mas também da sua organização espacial e temporal (Rao-Ruiz *et al.*, 2021).

Figura 12: Reorganização temporal de uma rede de células de engrama: o aprendizado ativa conjuntos específicos de neurônios em regiões como o hipocampo, o córtex e áreas subcorticais. A consolidação envolve fortalecimento sináptico entre essas células e reorganização da rede com maior dependência do córtex para evocação da memória remota.



Fonte: Adaptado de Rao-Ruiz *et al.* (2021)

Esses achados têm implicações diretas para o desenvolvimento de ferramentas educacionais baseadas em neurociência. A sincronização de *spikes*, a formação de *clusters* sinápticos e a regulação da plasticidade formam um tripé essencial para a codificação eficaz de informações complexas, como os conceitos abordados no ensino de Física. Ao estimular os alunos com tarefas que requerem atenção simultânea, memória operacional e raciocínio abstrato, como ocorre em jogos e simulações computacionais, é possível engajar múltiplos circuitos neurais de forma sinérgica. Hasani *et al.* (2022) e Dubreuil *et al.* (2022) destacam que redes neurais artificiais inspiradas em estruturas cerebrais podem modular padrões dinâmicos de forma eficiente, o que reforça a viabilidade de se aplicar esses princípios em contextos de aprendizagem. A compreensão de como os *clusters* sinápticos operam e se estabilizam no tempo oferece, portanto, uma base sólida para repensar o ensino como um processo adaptativo, dinâmico e biologicamente fundamentado.

### 3 METODOLOGIA

O artigo de Zheng *et al.* (2024) tem como principal objetivo apresentar um novo modelo de neurônio de pico, chamado DH-LIF (*Leaky Integrate-and-Fire* com Heterogeneidade Dendrítica Temporal), e redes neurais de pico baseadas nesse modelo, denominadas DH-SNNs, buscando melhorar a capacidade das SNNs (*Spiking Neural Networks*) de processar informações temporais em múltiplas escalas de tempo. A proposta parte da constatação de que os neurônios biológicos possuem propriedades temporais variadas, especialmente nos dendritos, o que não é adequadamente considerado nos modelos convencionais de redes neurais de pico (Zheng *et al.*, 2024).

O modelo DH-LIF incorpora múltiplos compartimentos dendríticos, cada um com seu próprio parâmetro de tempo, permitindo que a rede aprenda automaticamente dinâmicas temporais em diferentes escalas. Esse tipo de abordagem busca refletir de forma mais realista a complexidade do processamento temporal que ocorre em sistemas neurais reais (Izhikevich, 2004; Dayan; Abbott, 2005).

No artigo, os autores propõem uma abordagem em três etapas: primeiro, desenvolvem formalmente o modelo DH-LIF; em seguida, estendem esse modelo para redes *feedforward* (DH-SFNNs) e recorrentes (DH-SRNNs); por fim, testam essas redes em diferentes tarefas de *benchmark* envolvendo processamento temporal, como reconhecimento de fala, classificação de imagens e sinais de EEG. Os resultados mostram que as DH-SNNs superam modelos tradicionais em termos de precisão, robustez e eficiência energética, além de apresentarem melhor compactação do modelo (Zheng *et al.*, 2024).

Com isso, o trabalho contribui para aproximar os modelos artificiais das propriedades observadas nos sistemas neurais biológicos, oferecendo alternativas mais eficientes e biologicamente plausíveis para aplicações em computação neuromórfica e para tarefas que exigem o processamento de informações em múltiplas escalas temporais.

Em consonância com o que foi proposto por (Zheng *et al.*, 2024), iremos tratar a abordagem da variação da corrente de estímulo  $I_{\text{ext}}$  para a análise da propagação da informação transmitida ao longo de todo o corpo do neurônio em termos de duas condições de contorno. Primeiro, calcularemos para o valor constante da corrente externa; em seguida, consideraremos uma corrente externa variável, representada pela função degrau de Heaviside  $u(t - t_0)$ , que modela uma ativação súbita da corrente a partir de um instante específico  $t_0$ . Essa função vale zero para  $t < t_0$  e um para  $t \geq t_0$ , sendo amplamente utilizada na modelagem de sistemas dinâmicos com entradas abruptas. O objetivo é analisarmos a propagação da corrente de informação ao longo do neurônio. Iremos resolver uma equação diferencial ordinária (EDO) de primeira or-

dem não homogênea para correntes elétricas, pois, de acordo com a literatura, os ramos dos neurônios (chamados de dendritos) processam sinais elétricos da mesma forma que ocorre em circuitos elétricos, o que garante que as mesmas leis da eletricidade se aplicam ao processo de transmissão de sinais nas ramificações dos neurônios (Sussillo, 2014).

$$I_{d.ext}^t = C \frac{\partial u_d^t}{\partial t} + \frac{u_d^t}{R_T} + i_d^t \quad (3.1)$$

onde,

$$u_d^t = R_L i_d^t. \quad (3.2)$$

A equação (3.1) referente à corrente externa foi retirada de Sussillo (2014) para calcularmos a solução da EDO em termos das correntes elétricas dos dendritos e posteriormente analisarmos a robustez do sinal elétrico propagado ao longo dos ramos, levando à observação da atenuação lenta e rápida em relação à janela de tempo para os *spikes* específicos. Consideraremos a variação para a resistência  $R_T$  e para resistência associada à carga  $R_L$ .

Neste trabalho inicial levaremos em consideração a LIF (*Leak Integrate-and-Fire*), onde analisaremos a variação da corrente elétrica dendrítica e o potencial elétrico dendrítico em relação ao tempo, porém deixaremos o tratamento do processamento dos sinais de informação utilizando DH-LIF para uma continuidade futura desta pesquisa.

Utilizaremos o método do fator integrante para a resolução da EDO de primeira ordem não homogênea referente a equação (3.1). Reescrevendo a equação (3.1), isolaremos os termos conhecidos e os desconhecidos

$$I_{d.ext}^t - i_d^t = C \frac{du_d^t}{dt} + \frac{u_d^t}{R_T}. \quad (3.3)$$

Temos como objetivo resolver a equação (3.3) para  $u_d^t$  (potenciais nos dendritos). A constante  $C$  se refere a capacitância nos ramos.

Reorganizando a equação (3.3), teremos

$$\frac{1}{C} (I_{d.ext}^t - i_d^t) = \frac{du_d^t}{dt} + \frac{1}{CR_T} u_d^t. \quad (3.4)$$

A equação (3.4) é uma equação linear de primeira ordem do tipo

$$\frac{du}{dt} + P(t)u = Q(t), \quad (3.5)$$

com

$$P = \frac{1}{CR_T}; \quad (3.6)$$

$$Q = \frac{1}{C}(I_{d\_ext}^t - i_d^t). \quad (3.7)$$

A solução da equação (3.5) será obtida utilizando o método do fator integrante<sup>1</sup>.  $\mu(t) = e^{\int P dt} = e^{t/(CR_T)}$ . Multiplicando ambos os lados da equação pelo fator integrante, obteremos

$$\frac{d}{dt} \left[ u_d^t e^{t/(CR_T)} \right] = \frac{e^{t/(CR_T)}}{C} (I_{d\_ext}^t - i_d^t). \quad (3.8)$$

A solução para a equação (3.8) será

$$u_d^t = e^{-t/(CR_T)} \left[ \int \frac{1}{C} (I_{d\_ext}^t - i_d^t) e^{t/(CR_T)} dt + K \right], \quad (3.9)$$

onde  $K$  é a constante de integração definida pela condição de contorno  $u_d(0)$ .

Além da resolução analítica da equação (3.1) utilizando o método do fator integrante, também foi realizada a dedução completa das equações (1) a (4) apresentadas por Zheng *et al.* (2024), com o objetivo de reconstituir o processo de modelagem computacional da corrente dendrítica em sua forma contínua e discretizada. Essa dedução, que inclui os passos matemáticos intermediários e as definições de parâmetros como  $\tau_d$  e  $\alpha_d$ , encontra-se documentada no Anexo B, mas não será explorada diretamente na análise desenvolvida neste trabalho, uma vez que a investigação aqui proposta seguirá um enfoque distinto, com base em soluções analíticas e na comparação entre diferentes condições de contorno para a corrente externa.

---

<sup>1</sup>A demonstração do método do fator integrante está no Anexo A

## 4 DISCUSSÕES E RESULTADOS

Calcularemos, utilizando o Python, o potencial elétrico dos dendritos considerando a primeira condição inicial para a equação (3.8), com  $I_{d,ext}^t = I_0$  (constante) e  $i_d^t = 0$ , teremos

$$u_d^t = e^{-t/(CR_T)} \left[ \frac{I_0}{C} CR_T e^{t/(CR_T)} + K \right], \quad (4.1)$$

usaremos

$$\tau = CR_T, \quad (4.2)$$

dessa forma a equação (4.1) será reescrita da seguinte maneira

$$u_d^t = e^{-t/\tau} \left[ \frac{I_0}{C} \tau e^{t/\tau} + K \right]. \quad (4.3)$$

Simplificando a equação (4.3), teremos

$$u_d^t = I_0 R_T + K e^{-t/\tau}. \quad (4.4)$$

Ao adotarmos  $u_d(0) = 0$ , teremos

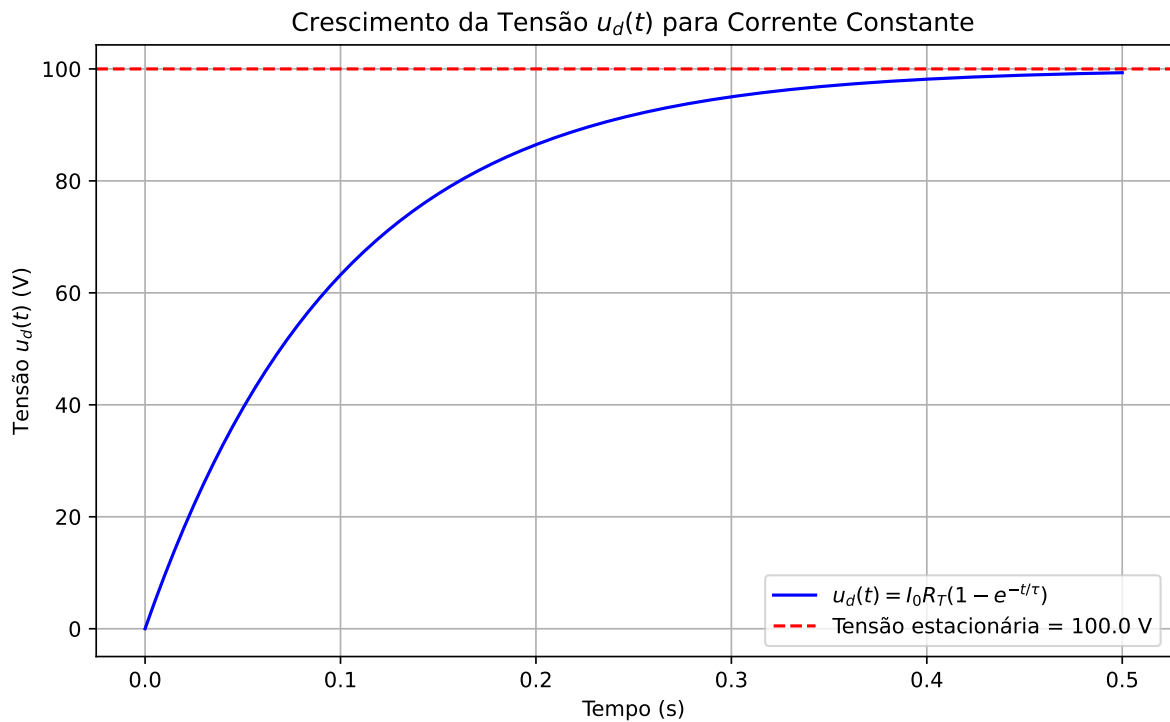
$$K = -I_0 R_T. \quad (4.5)$$

logo, a solução final referente a equação (4.4) será

$$u_d^t = I_0 R_T \left( 1 - e^{-t/\tau} \right). \quad (4.6)$$

De acordo com a equação (4.6) o potencial cresce exponencialmente de zero até um valor estacionário  $I_0 R_T$ . A constante  $\tau = CR_T$  governa a velocidade desse crescimento e esse comportamento é típico de um circuito  $RC$  ou modelos de integração passiva em neurônios.

Figura 13: Representação do crescimento exponencial do potencial dendrítico para  $I_{d,ext}^t = I_0$ .



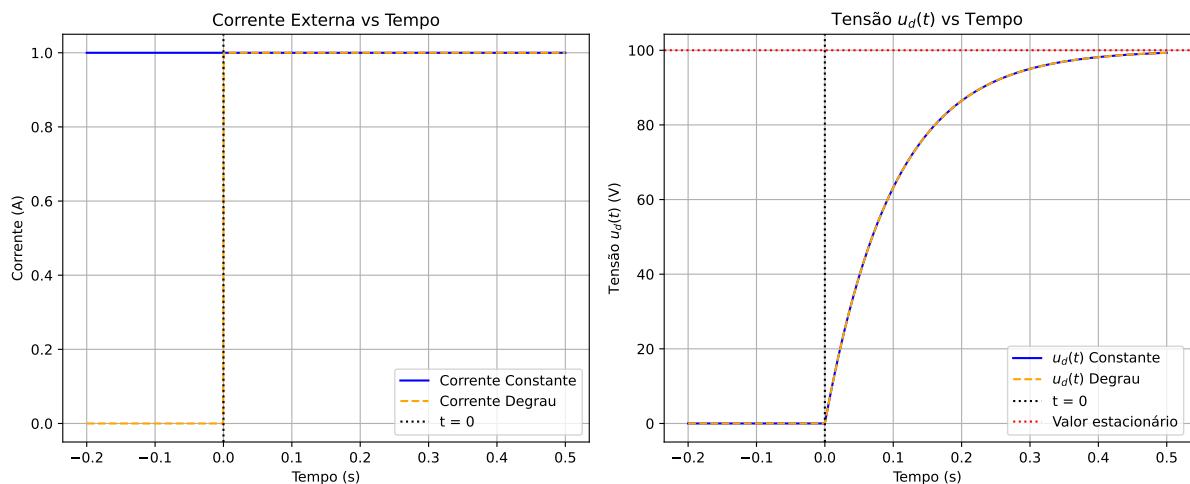
Fonte: Elaboração própria.

Quando utilizamos  $I_{d,ext}^t$  como uma função degrau de Heaviside, teremos

$$I_{d,ext}^t = I_0 H(t) = \begin{cases} 0, & \text{se } t < 0 \\ I_0, & \text{se } t \geq 0 \end{cases} \quad (4.7)$$

dessa maneira a solução geral será igual ao resultado da equação (4.6), salvo a diferença que para a primeira condição de contorno o valor ocorre para  $t < 0$ , em contrapartida, para a segunda condição de contorno referente à função degrau o resultado ocorre para  $t \geq 0$ .

Figura 14: Representação do crescimento exponencial do potencial dendrítico para  $I_{d,ext}^t = I_0 H(0)$ .

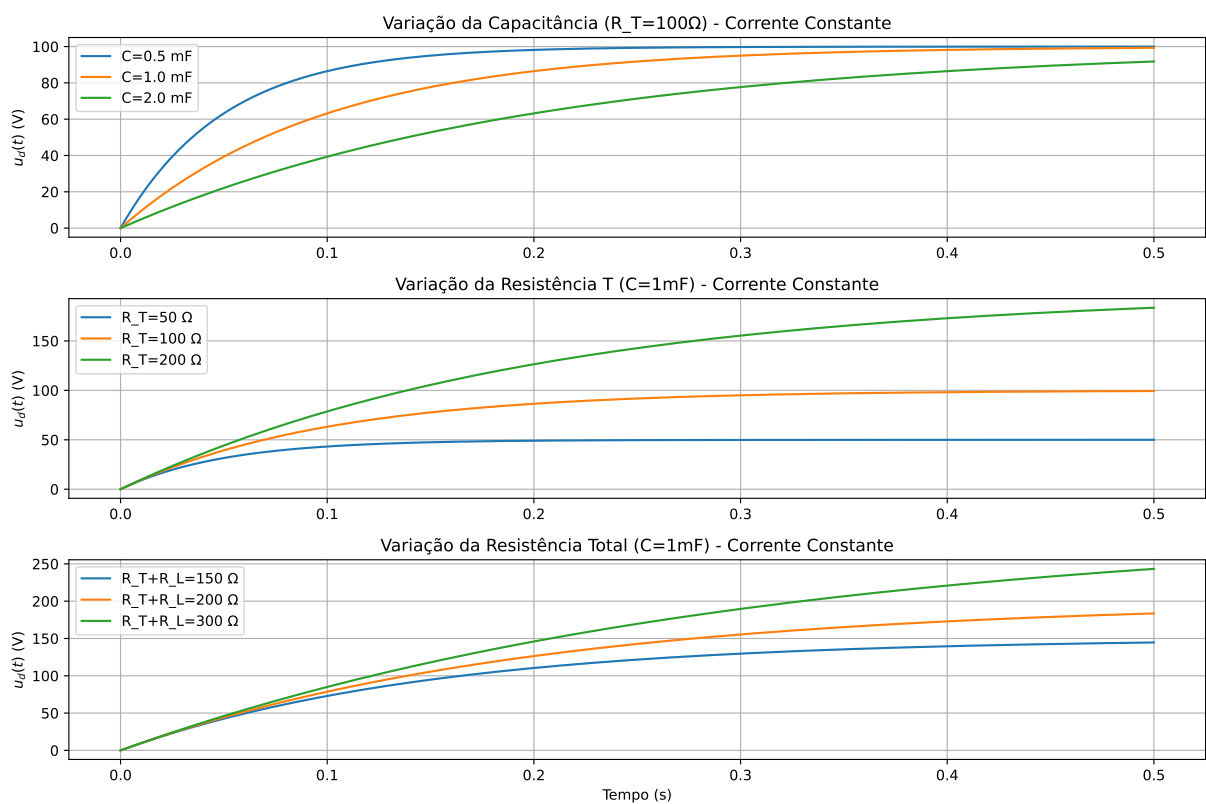


Fonte: Elaboração própria.

Para neurônios e sistemas biológicos, normalmente usa-se a função degrau de Heaviside, pois o estímulo inicia-se em um instante específico. Entretanto, para análise de sistemas em regime permanente, a corrente constante simplifica o cálculo quando desejamos ignorar o “antes do estímulo”.

Plotamos a seguir o gráfico para as variações da representação do crescimento exponencial do potencial dendrítico considerando uma corrente externa constante, onde variamos os valores da capacitância  $C$  e das resistências  $R_T$  e  $R_L$  para avaliarmos os crescimentos do potencial dendrítico e o impacto que essas variações causam na informação ao longo dos neurônios.

Figura 15: Variações da representação do crescimento exponencial do potencial dendrítico para  $I_{d.ext}^t = I_0$ .



Fonte: Elaboração própria.

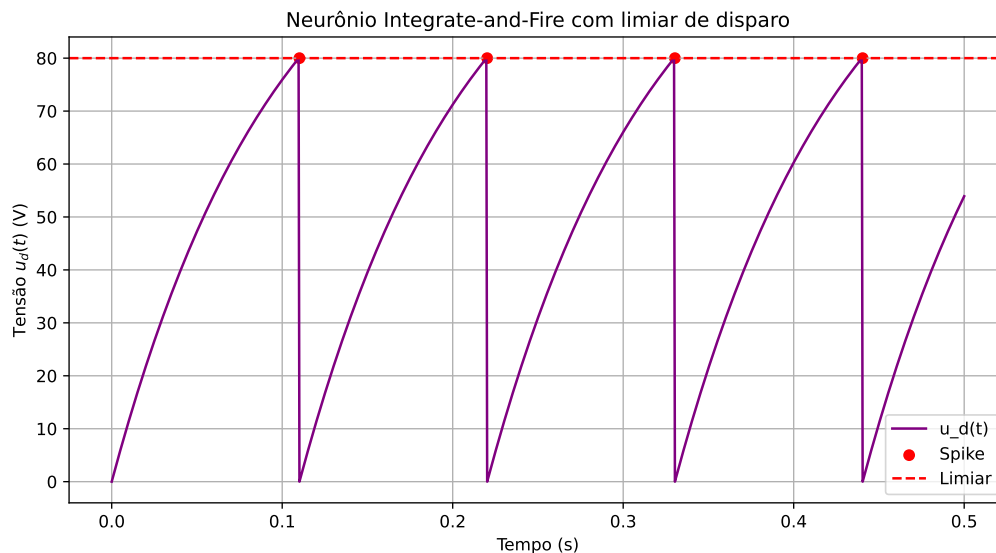
Um maior  $C$  representa uma membrana mais “lenta” para acumular carga (o potencial cresce mais devagar e a curva é mais esticada), porém, biologicamente, membranas neurais com alta capacitância filtram estímulos rápidos. Enquanto para um  $R_T$  maior teremos menos “drenagem” da carga (sobem mais lentamente e atingem um patamar mais alto), isso acarreta o fato da membrana levar mais tempo para carregar e, dessa forma, atinge um maior potencial, e isso torna a membrana mais isolante. Caso  $R_L$  represente alguma resistência de carga externa ou dendrítica, seu impacto é na resistência efetiva vista pelo capacitor.

Iremos analisar a informação sináptica através do potencial de ação, o qual é entendido como um pulso elétrico rápido e transitório que ocorre nos neurônios quando o potencial

da membrana ultrapassa o limiar crítico (ele é o principal mecanismo pelo qual os neurônios transmitem informações ao longo do axônio até atingir outras células). Utilizaremos um modelo matemático simples como o modelo *Integrate-and-Fire* que representa como um neurônio acumula corrente elétrica ao longo do tempo até atingir um limiar de disparo. Quando o limiar é atingido, o neurônio gera um *spike* (potencial de ação) e o potencial é resetado, repetindo este ciclo. O termo *Integrate* está relacionado a integrar (somar) correntes sinápticas recebidas ao longo do tempo, aumentando o potencial da membrana, enquanto o termo *Fire* é relacionado ao disparo (gerar *spike*) quando o potencial atinge um potencial limiar.

Plotamos um gráfico que mostra claramente o comportamento de um neurônio *Integrate-and-Fire* com limiar de disparo.

Figura 16: Dinâmica de um neurônio *Integrate-and-Fire*.

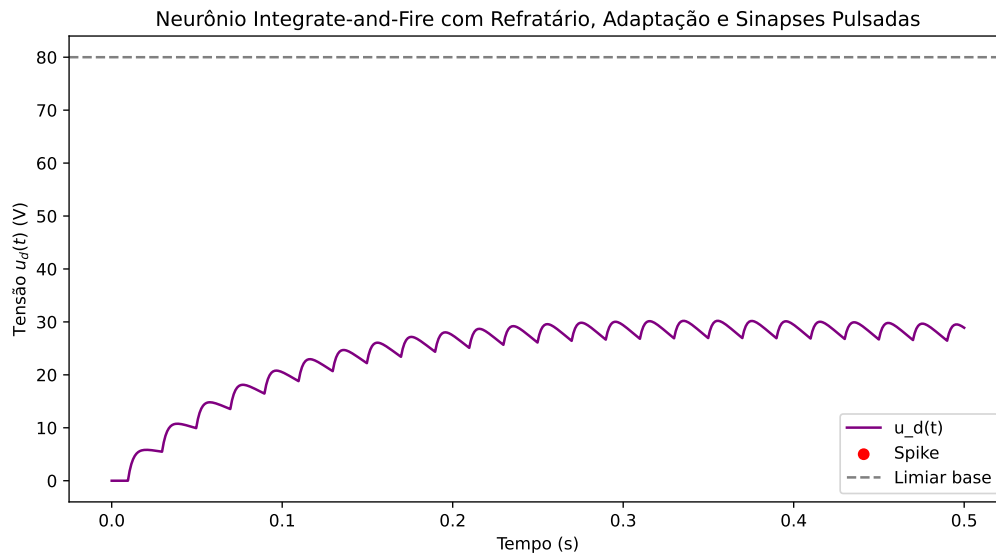


Fonte: Elaboração própria.

Na figura 16 o potencial cresce exponencialmente, como esperado pela integração da corrente no circuito *RC*, e o crescimento é suave e contínuo até atingir o limiar fixado (80 V). Biologicamente, este padrão representa o comportamento básico dos neurônios excitáveis, onde o disparo é acionado por um acúmulo de um potencial até um limiar. O intervalo entre disparos (ISI) é constante, o que sugere que a corrente de entrada é constante ou periódica, é o típico comportamento *firing regular*.

A análise da dinâmica do neurônio *Integrate-and-Fire* pode ser estendida ao considerar o período refratário absoluto o qual poderá ser incluído para deixar o potencial fixo em zero por um tempo após cada *spike*. Esta inclusão gera adaptação limiar para comportamentos mais realistas, onde o limiar poderá subir após cada *spike*. Plotamos o resultado da dinâmica *spike* para período refratário.

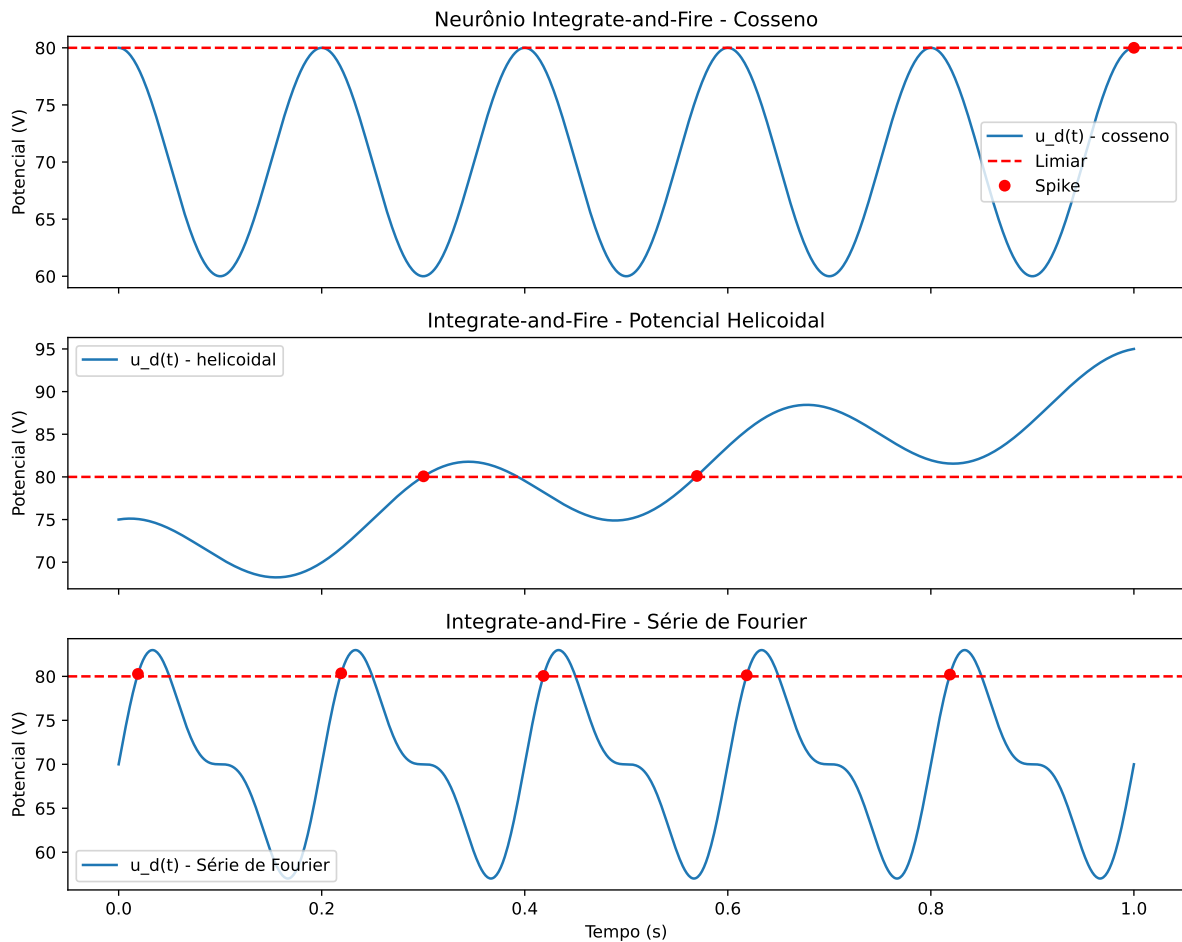
Figura 17: Dinâmica de um neurônio *Integrate-and-Fire* para período refratário.



Fonte: Elaboração própria.

Na figura 17 o gráfico mostra o comportamento do neurônio do tipo *Integrate-and-Fire* que incorporou o período refratário, a adaptação do limiar de disparo e as entradas sinápticas pulsadas. A linha roxa representa o potencial de membrana  $u_d(t)$  ao longo do tempo, enquanto os pontos vermelhos marcam os momentos em que o neurônio atingiria o limiar e dispara um *spike*, porém para o comportamento refratário o potencial não atinge o valor de (80 V) (não ocorre disparos para o comportamento refratário). A linha tracejada preta mostra o limiar base (estático) para referência. Em seguida, plotamos a dinâmica de um neurônio *Integrate-and-Fire* para funções do tipo cosseno, helicoidal e Série de Fourier.

Figura 18: Dinâmica de um neurônio *Integrate-and-Fire* para as funções cosseno, helicoidal e série de Fourier.



Fonte: Elaboração própria.

A figura 18 nos mostra a resposta do neurônio *Integrate-and-Fire* para uma corrente elétrica representada pela função cosseno a qual está relacionada ao potencial da membrana do neurônio no formato da função cosseno. Com a amplitude da oscilação é consistentemente maior que o limiar, o neurônio dispara *spikes* de forma altamente regular e rítmica (disparo tônico) e *spikes* ocorrem em intervalos de tempo fixos, demonstrando a capacidade do neurônio de manter um ritmo de disparo constante sob uma entrada periódica estável. No gráfico da função helicoidal, a amplitude da oscilação parece diminuir ou a linha de base se desloca, fazendo com que o potencial do neurônio se aproxime do limiar apenas em certas partes ou por um período limitado. Em relação à resposta do neurônio à função helicoidal de entrada, o neurônio dispara alguns *spikes* no início ou em momentos em que o potencial atinge o limiar. No entanto, à medida que a simulação avança, a oscilação do potencial pode não mais cruzar o limiar de forma consistente, resultando em um disparo irregular ou transiente, ou até mesmo na cessação dos *spikes*. Quando a função de entrada é uma Série de Fourier (a forma da onda é uma combinação de múltiplas senoides de diferentes frequências e amplitudes) o resultado é um sinal periódico mais complexo e não senoidal, e o potencial da membrana do neurônio

reflete a complexidade da entrada da série de Fourier. Apesar da forma de onda mais intrincada, o potencial cruza o limiar de forma consistente e periódica, gerando *spikes* e o padrão de disparo é mais rítmico, porém mais dinâmico, refletindo a estrutura complexa.

O gráfico do neurônio *Integrate-and-Fire* à função série de Fourier representa uma dinâmica mais interessante e, possivelmente, mais biologicamente relevante. Neurônios reais no cérebro raramente recebem entradas senoidais puras, em vez disso, suas entradas sinápticas são complexas, ruidosas e compostas por múltiplas frequências. A capacidade do modelo *Integrate-and-Fire* de responder de forma robusta e coerente a uma entrada complexa (como a de uma Série de Fourier) demonstra sua utilidade em aproximar o processamento de sinais mais sofisticados que ocorrem em redes neurais biológicas. A complexidade do sinal de entrada permite ao neurônio potencialmente codificar informações ricas em seu padrão de disparo.

## 5 IMPLICAÇÕES PEDAGÓGICAS DA DINÂMICA DE MEMÓRIA PARA O ENSINO DE FÍSICA NA EDUCAÇÃO BÁSICA

A compreensão dos mecanismos neurobiológicos relacionados à formação de memória e ao funcionamento de redes neurais apresenta grande relevância para o ensino de Física na Educação Básica, especialmente na formação inicial de professores. Ao considerar que o aprendizado ocorre por meio da modificação dinâmica das conexões sinápticas e da ativação coordenada de agrupamentos neuronais, torna-se possível elaborar propostas pedagógicas que respeitem os limites e potencialidades do funcionamento cerebral dos estudantes. Essa integração entre conhecimentos da neurociência e práticas educacionais reforça a ideia de que a aprendizagem eficaz depende tanto de condições externas, como estratégias didáticas, organização curricular e ambiente escolar, quanto de processos internos do sujeito, como atenção, memória, emoção e cognição integrada (Bear *et al.*, 2015; Moran, 2000).

Para que a proposta pedagógica esteja em consonância com os princípios e diretrizes da educação nacional, é fundamental que o ensino de Física na Educação Básica esteja alinhado aos objetivos estabelecidos pela Base Nacional Comum Curricular (BNCC). A BNCC orienta que o conhecimento na área de Ciências da Natureza seja estruturado a partir de leis, teorias e modelos, e destaca a importância do desenvolvimento de competências voltadas à elaboração e aplicação desses modelos na interpretação de fenômenos naturais e sistemas tecnológicos (Brasil *et al.*, 2018). Conforme o documento:

Na área de Ciências da Natureza, os conhecimentos conceituais são sistematizados em leis, teorias e modelos. A elaboração, a interpretação e a aplicação de modelos explicativos para fenômenos naturais e sistemas tecnológicos são aspectos fundamentais do fazer científico [...] (Brasil *et al.*, 2018, p. 548).

Essa diretriz dialoga diretamente com os pressupostos da neurociência educacional, uma vez que o desenvolvimento de modelos mentais capazes de representar abstrações científicas exige a ativação de estruturas cognitivas complexas, sustentadas por processos de memória, atenção, raciocínio e linguagem. Assim, integrar os avanços da neurociência ao ensino de Física não apenas fortalece os objetivos da BNCC, como também permite fundamentar metodologicamente práticas didáticas mais eficazes e alinhadas ao funcionamento do cérebro em aprendizagem.

Nesse contexto, a neurociência educacional fornece subsídios para repensar o ensino de Física como um processo não linear, ativo e biologicamente enraizado. A aprendizagem significativa, conforme proposta por Ausubel, ocorre quando novos conteúdos se ancoram de maneira estável em estruturas cognitivas já existentes (Ausubel *et al.*, 1978). Essa teoria converge com as evidências neurobiológicas que apontam para a necessidade de repetição espaçada,

associação emocional e variedade de estímulos sensoriais para a consolidação das memórias de longo prazo. Do ponto de vista pedagógico, isso implica a necessidade de estratégias que promovam não apenas a memorização, mas a reconstrução ativa do conhecimento por meio da interação social e da resolução de problemas contextualizados (Vigotsky *et al.*, 1987; Moreira, 1985).

As metodologias de ensino por investigação, aprendizagem baseada em problemas (PBL) e o uso de tecnologias digitais, como jogos, simulações interativas e ambientes de programação, alinham-se aos princípios da codificação neural eficiente discutidos nos capítulos anteriores. Ao estimular simultaneamente a atenção coletiva, o envolvimento emocional e a integração multimodal da informação (visual, tátil e verbal), essas abordagens favorecem o disparo coordenado de neurônios em padrões recorrentes, que formam a base para a consolidação de traços de memória duradouros. Estudos recentes sugerem que essas práticas potencializam a retenção e a transferência do conhecimento ao longo do tempo (Camillo, 2021; Kenski, 2003). Além disso, o uso de ferramentas como Python, Scratch e ambientes de simulação como PhET Colorado, quando inserido em contextos experimentais e investigativos, promove o fortalecimento sináptico por meio de experiências realmente significativas, lúdicas e desafiadoras, respeitando os ritmos cognitivos individuais dos estudantes.

Por exemplo, diversas pesquisas em neuroeducação mostraram que o uso do Jupyter Notebook com Python permite que os alunos manipulem dados reais de experimentos neurais e construam visualizações interativas, o que contribui não apenas para a compreensão conceitual, mas também para a consolidação de padrões cognitivos por meio de *feedback* imediato e visualização multimodal (Tufino *et al.*, 2025). O estudo de Suriyaarachchi *et al.* (2025) sobre aprendizagem com Python, baseado no paradigma de *productive failure*, demonstrou que estudantes que primeiro tentaram resolver problemas difíceis antes da instrução formal apresentaram maior retenção conceitual e menor carga cognitiva posterior. Outra investigação comparou o uso de Scratch e Python e observou que ambos os ambientes geram atividade cerebral consistente durante a programação, com redução no tempo de resolução de tarefas à medida que os alunos dominam cada linguagem, o que indica que práticas interativas consolidadas contribuem para processos cognitivos automatizados e eficientes (Ivanova *et al.*, 2020). Simulações PhET, por sua vez, têm sido amplamente documentadas como eficazes para aumentar a motivação dos alunos e sua compreensão de conceitos abstratos em Física, como ondas e equilíbrio, especialmente por meio de visualizações dinâmicas que permitem explorar sem restrições experimentais reais (Wieman *et al.*, 2008; Umiliya *et al.*, 2023; Wieman; Perkins, 2005; Rayan *et al.*, 2023; Wieman *et al.*, 2010; Podolefsky *et al.*, 2013). Esses achados sustentam a ideia de que tecnologias abertas e interativas contribuem diretamente para a codificação neural reforçada e para a aprendizagem significativa.

Além disso, os princípios da zona de desenvolvimento proximal, conforme Vygotsky, reforçam que a mediação ativa do docente é essencial para guiar estudantes em atividades desafiadoras, diagnosticando conhecimentos prévios e oferecendo suporte adequado. Na perspectiva da neurociência educacional, essa mediação assume formas de diálogo, estímulo emocional e cooperação social, catalisando a ativação de circuitos neurais emergentes. Essa abordagem, respaldada pela teoria da aprendizagem significativa e pela didática construtivista de Libâneo, favorece práticas sensíveis às diferenças cognitivas individuais e ao histórico de cada aluno, configurando um ambiente escolar estimulante e acolhedor (Libâneo, 2013; Ausubel *et al.*, 1978; Moreira, 1985). Esse tipo de intervenção docente estimula a formação de redes neurais complexas e adaptativas, permitindo que os estudantes avancem em direção a representações cognitivas mais sofisticadas de fenômenos físicos.

As implicações pedagógicas da dinâmica da memória cerebral no ensino de Física indicam a necessidade de um currículo que vá além da exposição passiva de conteúdos. É importante promover processos de aprendizagem que valorizem a experimentação ativa, a resolução de problemas e o uso articulado de diferentes formas de representação, como expressões matemáticas, modelos gráficos, códigos computacionais, esquemas simbólicos e a linguagem oral e escrita. Ao trabalhar esses diversos modos de expressão em atividades práticas e investigativas, os estudantes conseguem compreender e representar os fenômenos físicos de forma mais integrada, o que favorece tanto a aprendizagem conceitual quanto a consolidação do conhecimento. Nesse contexto, a escola deve se estruturar como um ambiente planejado intencionalmente para favorecer a construção de saberes por meio do engajamento dos estudantes, permitindo que a aprendizagem se torne mais significativa, contextualizada e duradoura. Integrando saberes da neurociência à prática docente, essa abordagem fortalece o papel do professor como mediador entre o conhecimento científico e os processos mentais envolvidos na aprendizagem. Quando atua de forma consciente e reflexiva, o docente contribui para a formação de conexões entre os conceitos da Física, os métodos de investigação e as estruturas cognitivas dos alunos, promovendo uma aprendizagem sólida, ativa e fundamentada em evidências científicas.

## 6 CONCLUSÃO

A modelagem estrutural cerebral tem se mostrado fundamental para a compreensão da eficiência da cognição, ao demonstrar que a arquitetura das redes neurais exerce influência direta sobre a forma como informações são processadas, armazenadas e evocadas. Estruturas cerebrais organizadas em padrões topológicos específicos promovem integração funcional entre diferentes regiões do sistema nervoso central, viabilizando o surgimento de pensamentos complexos e adaptativos. Essa organização estrutural permite a sincronização coordenada de *clusters* sinápticos e favorece a formação de trajetórias dinâmicas de ativação que sustentam estados cognitivos estáveis, condição essencial para a manutenção da memória e do aprendizado. Como evidenciado no presente trabalho, redes densamente conectadas apresentam maior robustez, eficiência energética e seletividade funcional, o que reforça a importância da estrutura anatômica cerebral como base para a otimização do desempenho cognitivo.

Analisar o potencial de ação nos dendritos por meio do modelo LIF oferece uma base conceitual para entender como as informações são processadas localmente nas ramificações dendríticas, influenciando a atividade elétrica neuronal. O modelo demonstra que os sinais sinápticos se acumulam exponencialmente (equação (4.6), figuras 13, 14, 15) até superar um limiar, desencadeando o disparo. Essa estrutura matemática representa a integração espaço-temporal de estímulos excitatórios e inibitórios, traduzindo de forma acessível a complexidade da computação neural biológica. Além disso, revela o papel ativo e influente dos dendritos na seleção e modulação de padrões de entrada nos mecanismos de aprendizado e consolidação de memórias, conforme evidenciado nas simulações e discussões deste trabalho.

A análise da corrente externa dendrítica ( $I_{d,ext}$ ) revelou que a forma do estímulo influencia diretamente a ativação coordenada de sinapses em compartimentos dendríticos. Estímulos do tipo degrau de Heaviside ( $I_0H(t)$ ), por simularem entradas biológicas com início definido, favoreceram uma sincronização mais eficiente, essencial para a formação de *clusters* sinápticos estáveis. Além disso, parâmetros como capacitância ( $C$ ) e resistência total ( $R_T$ ) regularam a velocidade de integração do sinal, com maior  $C$  resultando em respostas mais lentas e maior  $R_T$  amplificando o potencial final, o que favoreceu a persistência de padrões recorrentes de ativação. Esses achados reforçam que a dinâmica temporal do estímulo, aliada às propriedades elétricas dos dendritos, é fundamental para a estruturação de *clusters* funcionais e a consolidação de memória.

Buscou-se, neste trabalho, analisar como a heterogeneidade presente nos compartimentos dendríticos pode favorecer o surgimento de *clusters* sinápticos estáveis, por meio da modelagem com neurônios LIF. Os resultados indicam que as propriedades elétricas locais dos

compartimentos dendríticos, como a capacitância e a resistência total, modulam a integração espaço-temporal (figuras 13 a 17), favorecendo a sincronização de sinapses em agrupamentos funcionais. Como continuidade, propõe-se incorporar constantes de tempo distintas entre compartimentos dendríticos (modelo DH-LIF), com o objetivo de simular a formação simultânea de *clusters* independentes. Essa abordagem permitirá identificar condições críticas para a consolidação de memórias e desenvolver arquiteturas neurais bioinspiradas com maior eficiência energética e capacidade computacional.

Neste trabalho, ao buscarmos compreender como o nosso cérebro funciona, como ele lembra e aprende, contribuímos para além da discussão sobre modelos computacionais e análises teóricas e experimentais sobre redes neurais, *clusters* e sinapses. Estamos nos apropriando de ferramentas transformadoras, capazes de impactar não apenas a nossa prática docente, mas também todos os envolvidos no processo educativo. Ao desvendar os mecanismos da mente humana, assumimos o compromisso de manter um olhar atento à ciência e sensível à educação, promovendo um diálogo entre os conhecimentos discutidos e as urgências de uma educação mais acolhedora, empática, potente, transformadora e, sobretudo, humana.

## REFERÊNCIAS

- AUSUBEL, D. P.; NOVAK, J. D.; HANESIAN, H. **Educational psychology**: a cognitive view. New York: Holt, Rinehart and Winston, 1978.
- BASSETT, D. S.; SPORNS, O. Network neuroscience. **Nature Neuroscience**, New York, v. 20, n. 3, 2017. p. 353-364
- BASSI, M. S. *et al.* Synaptic plasticity shapes brain connectivity: implications for network topology. **International Journal of Molecular Sciences**, v. 20, n. 24, p. 6193, 2019.
- BEAR, M.; CONNORS, B.; PARADISO, M. **Neuroscience**: exploring the brain. 4. ed. internacional. Burlington: Jones & Bartlett Learning, 2015.
- BENA, G.; GOODMAN, D. F. Dynamics of specialization in neural modules under resource constraints. **Nature Communications**, London, v. 16, n. 1, p. 187, 2025.
- BORGES, R. R. *et al.* Synaptic plasticity and spike synchronisation in neuronal networks. **Brazilian Journal of Physics**, v. 47, n. 6, p. 678-688, 2017.
- BRASIL, M. *et al.* **Base nacional comum curricular**. Brasília-DF: MEC, Secretaria de Educação Básica, 2018.
- BUZSAKI, G.; DRAGUHN, A. Neuronal oscillations in cortical networks. **Science**, v. 304, n. 5679, p. 1926-1929, 2004.
- BUZSAKI, G.; MIZUSEKI, K. The log-dynamic brain: how skewed distributions affect network operations. **Nature Reviews Neuroscience**, London, v. 15, n. 4, p. 264-278, 2014.
- CAMILLO, C. M. Neurociência e a aprendizagem no ensino ciências. **Research, Society and Development**, v. 10, n. 6, p. e20510615721, 2021.
- CAPORALE, N.; DAN, Y. Spike timing-dependent plasticity: a hebbian learning rule. **Annual Review of Neuroscience**, v. 31, n. 1, p. 25-46, 2008.
- DAYAN, P.; ABBOTT, L. F. **Theoretical neuroscience**: computational and mathematical modeling of neural systems. Cambridge: MIT Press, 2005.
- DEBANNE, D.; INGLEBERT, Y. Spike timing-dependent plasticity and memory. **Current Opinion in Neurobiology**, v. 80, p. 102707, 2023.
- DUBREUIL, A. *et al.* The role of population structure in computations through neural dynamics. **Nature Neuroscience**, v. 25, n. 6, p. 783-794, 2022.
- FINNIE, P. S.; NADER, K. The role of metaplasticity mechanisms in regulating memory destabilization and reconsolidation. **Neuroscience & Biobehavioral Reviews**, v. 36, n. 7, p. 1667-1707, 2012.
- GROSMARK, A. D.; BUZSAKI, G. Diversity in neural firing dynamics supports both rigid and learned hippocampal sequences. **Science**, v. 351, n. 6280, p. 1440-1443, 2016.

- HASANI, R. *et al.* Closed-form continuous-time neural networks. **Nature Machine Intelligence**, v. 4, n. 11, p. 992-1003, 2022.
- IOANNIDES, G. *et al.* Spatiotemporal dynamics in spiking recurrent neural networks using modified-full-force on eeg signals. **Scientific reports**, v. 12, n. 1, p. 2896, 2022.
- IVANOVA, A. A. *et al.* Comprehension of computer code relies primarily on domain-general executive brain regions. **Elife**, v. 9, p. e58906, 2020.
- IZHIKEVICH, E. M. Which model to use for cortical spiking neurons? **IEEE transactions on neural networks**, v. 15, n. 5, p. 1063-1070, 2004.
- JIN, Y.; ZHANG, W.; LI, P. Hybrid macro/micro level backpropagation for training deep spiking neural networks. **Advances in neural information processing systems**, v. 31, 2018.
- KANDEL, E. R. *et al.* The molecular and systems biology of memory. **Cell**, v. 157, n. 1, p. 163-186, 2014.
- KASTELLAKIS, G. *et al.* Synaptic clustering within dendrites: an emerging theory of memory formation. **Progress in neurobiology**, v. 126, p. 19-35, 2015.
- KENSKI, V. M. **Educação e tecnologias: o novo ritmo da informação**. Campinas: Papirus, 2003.
- KIM, R.; SEJNOWSKI, T. J. Strong inhibitory signaling underlies stable temporal dynamics and working memory in spiking neural networks. **Nature neuroscience**, v. 24, n. 1, p. 129-139, 2021.
- LIBÂNIO, J. C. Didática na formação de professores: entre a exigência democrática de formação cultural e científica e as demandas das práticas socioculturais. *In*: SANTOS, A.; SUANNO, M. V. **Didática e formação de professores: novos tempos, novos modos de aprender e ensinar**. Porto Alegre: Sulina, 2013. p. 51-82
- LODI, M. *et al.* Analyzing synchronized clusters in neuron networks. **Scientific Reports**, v. 10, n. 1, p. 16336, 2020.
- MAASS, W. Searching for principles of brain computation. **Current Opinion in Behavioral Sciences**, v. 11, p. 81-92, 2016.
- MAKINO, H.; MALINOW, R. Compartmentalized versus global synaptic plasticity on dendrites controlled by experience. **Neuron**, v. 72, n. 6, p. 1001-1011, 2011.
- MENG, Q. *et al.* Training high-performance low-latency spiking neural networks by differentiation on spike representation. *In*: **Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition**, p. 12444-12453, 2022.
- MILLER, E. K.; COHEN, J. D. An integrative theory of prefrontal cortex function. **Annual Review of Neuroscience**, v. 24, n. 1, p. 167-202, 2001.
- MONGILLO, G. *et al.* Synaptic theory of working memory. **Science**, v. 319, n. 5869, p. 1543-1546, 2008.

- MORAN, J. M. **Novas tecnologias e mediação pedagógica**. Campinas: Papirus, 2000.
- MOREIRA, M. A. **Ensino e aprendizagem**: enfoques teóricos. São Paulo: Moraes, 1985.
- NESSLER, B. *et al.* Bayesian computation emerges in generic cortical microcircuits through spike-timing-dependent plasticity. **PLoS Computational Biology**, v. 9, n. 4, p. e1003037, 2013.
- OLIVEIRA, L. F. de. Transmissão sináptica. **Brazilian Journal of Anesthesiology**, v. 44, n. 1, p. 25-33, 2020.
- PANZERI, S. *et al.* The structures and functions of correlations in neural population codes. **Nature Reviews Neuroscience**, v. 23, n. 9, p. 551-567, 2022.
- PERICH, M. G. *et al.* A neural population mechanism for rapid learning. **Neuron**, v. 100, n. 4, p. 964-976, 2018.
- PODOLEFSKY, N. S. *et al.* **Implicit scaffolding in interactive simulations**: design strategies to support multiple educational goals. arXiv preprint arXiv:1306.6544, 2013.
- RAO-RUIZ, P. *et al.* A synaptic framework for the persistence of memory engrams. **Frontiers in Synaptic Neuroscience**, v. 13, p. 661476, 2021.
- RAYAN, B. *et al.* Integrating PhET simulations into elementary science education: a qualitative analysis. **Education Sciences**, v. 13, n. 9, p. 884, 2023.
- RUNFOLA, C. *et al.* A mechanism for the emergence of low-dimensional structures in brain dynamics. **NPJ Systems Biology and Applications**, v. 11, n. 1, p. 32, 2025.
- SAKEMI, Y. *et al.* Sparse-firing regularization methods for spiking neural networks with time-to-first-spike coding. **Scientific Reports**, v. 13, n. 1, p. 22897, 2023.
- SALAJ, D. *et al.* Spike frequency adaptation supports network computations on temporally dispersed information. **Elife**, v. 10, p. e65459, 2021.
- SHOTA, Z. *et al.* Cell-specific synaptic plasticity induced by network oscillations. **Elife**, v. 5, 2016.
- SOUSA, L. B. *et al.* Neuroeducation: an approach to brain plasticity in learning. **Amadeus International Multidisciplinary Journal**, v. 4, n. 7, p. 86-104, 2019.
- STANOJEVIC, A. *et al.* High-performance deep spiking neural networks with 0.3 spikes per neuron. **Nature Communications**, v. 15, n. 1, p. 6793, 2024.
- SUBRAMONEY, A. *et al.* Fast learning without synaptic plasticity in spiking neural networks. **Scientific Reports**, v. 14, n. 1, p. 8557, 2024.
- SURIYAARACHCHI, H. *et al.* Investigating the use of productive failure as a design paradigm for learning introductory python programming. *In: Proceedings of the 56th ACM Technical Symposium on Computer Science Education*, v. 1, p. 1085-1091, 2025.

SUSSILLO, D. Neural circuits as computational dynamical systems. **Current opinion in neurobiology**, v. 25, p. 156-163, 2014.

TONEGAWA, S. *et al.* The role of engram cells in the systems consolidation of memory. **Nature Reviews Neuroscience**, v. 19, n. 8, p. 485-498, 2018.

TUFINO, E. *et al.* Using Jupyter notebooks to foster computational skills and professional practice in an introductory physics lab course *In: Journal of Physics: conference series*, v. 2950, n. 1, p. 012022, 2025.

UMILIYA, U. *et al.* The effectiveness of the application of PhET with inquiry learning model to improve understanding of the concept. **Journal of Science Education Research**, v. 7, n. 2, p. 82-92, 2023.

VIGOTSKY, L. S. *et al.* **Pensamento e linguagem**. São Paulo: Martins Fontes, 1987.

WANG, Y. *et al.* A universal ANN-to-SNN framework for achieving high accuracy and low latency deep spiking neural networks. **Neural networks**, v. 174, p. 106244, 2024.

WIEMAN, C.; PERKINS, K. Transforming physics education. **Physics today**, v. 58, n. 11, p. 36-41, 2005.

WIEMAN, C. E. *et al.* Teaching physics using PhET simulations. **The Physics Teacher**, v. 48, n. 4, p. 225-227, 2010.

WIEMAN, C. E. *et al.* PhET: simulations that enhance learning. **Science**, v. 322, n. 5902, p. 682-683, 2008.

YU, Q. *et al.* A brain-inspired spiking neural network model with temporal encoding and learning. **Neurocomputing**, v. 138, p. 3-13, 2014.

ZADOR, A. M. A critique of pure learning and what artificial neural networks can learn from animal brains. **Nature communications**, v. 10, n. 1, p. 3770, 2019.

ZHANG, Z. *et al.* Physics-informed neural networks with hybrid Kolmogorov-Arnold network and augmented Lagrangian function for solving partial differential equations. **Scientific Reports**, v. 15, n. 1, p. 10523, 2025.

ZHENG, H. *et al.* Temporal dendritic heterogeneity incorporated with spiking neural networks for learning multi-timescale dynamics. **Nature Communications**, v. 15, n. 1, p. 277, 2024.

ZHOU, C. *et al.* Direct training high-performance deep spiking neural networks: a review of theories and methods. **Frontiers in Neuroscience**, v. 18, p. 1383844, 2024.

## ANEXO A – DEMONSTRAÇÃO DO MÉTODO DO FATOR INTEGRANTE

A equação (A.1), apresentada na seção de métodos matemáticos, é uma equação diferencial linear de primeira ordem:

$$I_{d.ext}^t = C \frac{\partial u_d^t}{\partial t} + \frac{u_d^t}{R_T} + i_d^t \quad (\text{A.1})$$

Reorganizando os termos, podemos reescrevê-la como:

$$\frac{du}{dt} + P(t) \cdot u(t) = Q(t) \quad (\text{A.2})$$

em que:

$$P(t) = \frac{1}{CR_T}, \quad (\text{A.3})$$

$$Q(t) = \frac{1}{C}(I_{d.ext}^t - i_d^t). \quad (\text{A.4})$$

Para resolver a equação (A.2), utilizamos o método do fator integrante, que consiste em multiplicar todos os termos da equação por uma função  $\mu(t)$ :

$$\mu(t) \cdot \frac{du}{dt} + \mu(t) \cdot P(t) \cdot u(t) = \mu(t) \cdot Q(t) \quad (\text{A.5})$$

Aplicando a regra da derivada do produto:

$$\frac{d}{dt}[u(t) \cdot v(t)] = u(t) \cdot v'(t) + u'(t) \cdot v(t) \quad (\text{A.6})$$

e identificando  $v(t) = \mu(t)$ , podemos reescrever:

$$\frac{d}{dt}[\mu(t) \cdot u(t)] = \mu(t) \cdot \frac{du}{dt} + \frac{d\mu}{dt} \cdot u(t) \quad (\text{A.7})$$

Para que o lado esquerdo da equação (A.5) seja equivalente ao lado esquerdo de A.7, é necessário que:

$$\frac{d\mu}{dt} = \mu(t) \cdot P(t) \quad (\text{A.8})$$

Substituindo A.8 em A.5, obtemos:

$$\mu(t) \cdot \frac{du}{dt} + \frac{d\mu}{dt} \cdot u(t) = \mu(t) \cdot Q(t) \quad (\text{A.9})$$

Para encontrar a função  $\mu(t)$ , resolvemos a equação (A.8):

$$\frac{d\mu}{dt} = \mu(t) \cdot P(t) \quad (\text{A.10})$$

Separando as variáveis:

$$\frac{d\mu}{\mu} = P(t) dt \quad (\text{A.11})$$

Integrando ambos os lados:

$$\frac{d\mu}{\mu} = P(t) dt \quad (\text{A.12})$$

$$\ln|\mu(t)| = P(t) dt \quad (\text{A.13})$$

Aplicando a exponencial nos dois lados:

$$\mu(t) = e^{P(t) dt} \quad (\text{A.14})$$

Como  $P(t) = \frac{1}{CR_T}$ , segue que:

$$\mu(t) = e^{\frac{t}{CR_T} dt} = e^{\frac{t}{CR_T}} \quad (\text{A.15})$$

Sabendo disso, podemos calcular:

$$\frac{d\mu}{dt} = \frac{1}{CR_T} \cdot e^{\frac{t}{CR_T}} \quad (\text{A.16})$$

Substituindo os valores de  $\mu(t)$ ,  $\frac{d\mu}{dt}$  e  $Q(t)$  na equação (A.9), temos:

$$e^{\frac{t}{CR_T}} \cdot \frac{du}{dt} + \frac{1}{CR_T} e^{\frac{t}{CR_T}} \cdot u(t) = e^{\frac{t}{CR_T}} \cdot \frac{1}{C} (I_{d\_ext}^t - i_d^t) \quad (\text{A.17})$$

O lado esquerdo da equação pode ser reescrito como a derivada de um produto:

$$\frac{d}{dt} \left( u \cdot e^{\frac{t}{CR_T}} \right) = e^{\frac{t}{CR_T}} \cdot \frac{1}{C} (I_{d\_ext}^t - i_d^t) \quad (\text{A.18})$$

Portanto, demonstramos que a equação que modela o potencial dendrítico pode ser resolvida analiticamente pelo método do fator integrante, conforme apresentado na seção de métodos matemáticos.

**ANEXO B – DEDUÇÃO DAS EQUAÇÕES DE MODELAGEM DA CORRENTE  
DENDRÍTICA COM DISCRETIZAÇÃO TEMPORAL**

$$I_{d.ext}^t = C \frac{\partial u_d^t}{\partial t} + \frac{u_d^t}{R_T} + i_d^t, \quad u_d^t = R_L i_d^t \quad (\text{B.1})$$

**Equação (1):**

$$I_{d.ext}^t = C \frac{du_d^t}{dt} + \frac{u_d^t}{R_T} + i_d^t \quad (\text{B.2})$$

Sabendo que  $u_d^t = R_L i_d^t$ , substituímos na equação:

$$I_{d.ext}^t = C \frac{d(R_L i_d^t)}{dt} + \frac{R_L i_d^t}{R_T} + i_d^t \quad (\text{B.3})$$

Distribuindo e reorganizando:

$$I_{d.ext}^t = CR_L \frac{di_d^t}{dt} + i_d^t \left( \frac{R_L}{R_T} + 1 \right) \quad (\text{B.4})$$

Reorganizando a equação para isolar o termo que contém a derivada do lado esquerdo:

$$CR_L \frac{di_d^t}{dt} = I_{d.ext}^t - i_d^t \left( \frac{R_L + R_T}{R_T} \right) \quad (\text{B.5})$$

Multiplicando ambos os lados da equação anterior por  $\frac{R_T}{R_L + R_T}$ , temos:

$$C \frac{R_L R_T}{R_L + R_T} \frac{di_d^t}{dt} = \left( I_{d.ext}^t \cdot \frac{R_T}{R_L + R_T} \right) - i_d^t \quad (\text{B.6})$$

Definimos:

$$\tau_d = C \frac{R_L R_T}{R_L + R_T}, \quad I_d^t = I_{d.ext}^t \cdot \frac{R_T}{R_L + R_T}$$

Note que  $\tau_d$  representa a **constante de tempo efetiva** do circuito dendrítico, análoga àquela encontrada em circuitos elétricos do tipo RC. Essa constante resulta do produto da capacitância  $C$  pela resistência equivalente  $R_{eq}$ , obtida pela associação dos resistores  $R_L$  e  $R_T$  em paralelo:

$$R_{eq} = \frac{R_L R_T}{R_L + R_T}$$

Assim, podemos escrever

$$\tau_d = C \cdot R_{eq}$$

Portanto, a equação (B.6) pode ser reescrita como:

$$\tau_d \frac{di_d^t}{dt} = -i_d^t + I_d^t \quad (\text{B.7})$$

Esta é a **Equação (2)** do modelo, que descreve a evolução temporal da corrente dendrítica  $i_d^t$  a partir de uma equação diferencial de primeira ordem, típica de sistemas com dinâmica de relaxamento.

Para simular computacionalmente esse comportamento ao longo do tempo, aplicamos o **método de Euler Forward**, uma técnica numérica de discretização de derivadas no tempo. Essa abordagem aproxima a derivada temporal por uma diferença finita:

$$\frac{di_d^t}{dt} \approx \frac{i_d^{t+1} - i_d^t}{\Delta t}$$

Assumindo um passo de tempo unitário ( $\Delta t = 1$ ), a equação anterior se torna:

$$\tau_d (i_d^{t+1} - i_d^t) = -i_d^t + I_d^t \quad (\text{B.8})$$

Essa é a **Equação (3)** apresentada no artigo, que já corresponde a uma forma discreta da equação original, adequada para implementação computacional em domínios discretos de tempo.

Reorganizando os termos para explicitar  $i_d^{t+1}$ :

$$\tau_d i_d^{t+1} - \tau_d i_d^t = -i_d^t + I_d^t \quad (\text{B.9})$$

$$\tau_d i_d^{t+1} = (\tau_d - 1) i_d^t + I_d^t \quad (\text{B.10})$$

$$i_d^{t+1} = \left( \frac{\tau_d - 1}{\tau_d} \right) i_d^t + \left( \frac{1}{\tau_d} \right) I_d^t \quad (\text{B.11})$$

Introduzimos, então, um parâmetro auxiliar chamado **fator de decaimento temporal**, definido como:

$$\alpha_d = \frac{\tau_d - 1}{\tau_d} \quad \Rightarrow \quad 1 - \alpha_d = \frac{1}{\tau_d}$$

Substituindo esses valores na equação (B.11), obtemos a forma final da dinâmica discreta da corrente dendrítica:

$$i_d^{t+1} = \alpha_d i_d^t + (1 - \alpha_d) I_d^{t+1} \quad (\text{B.12})$$

Esta é a **Equação (4)** do artigo, que evidencia a contribuição ponderada entre o estado passado  $i_d^t$  e o novo estímulo efetivo  $I_d^{t+1}$ , refletindo o comportamento de um sistema com memória e amortecimento temporal.