

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL  
ESCOLA DE ENGENHARIA  
DEPARTAMENTO DE ENGENHARIA ELÉTRICA

Eduardo Pellin Moser

**Análise estocástica do comportamento elétrico  
de neurônios naturais e células ReRam**

Porto Alegre

2023

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL  
ESCOLA DE ENGENHARIA  
DEPARTAMENTO DE ENGENHARIA ELÉTRICA

Eduardo Pellin Moser

**Análise estocástica do comportamento elétrico de  
neurônios naturais e células ReRam**

Projeto de Diplomação II, apresentado ao Departamento de Engenharia Elétrica da Escola de Engenharia da Universidade Federal do Rio Grande do Sul, como requisito parcial para a obtenção do grau de Engenheiro Eletricista

UFRGS

Orientador: Prof. Dr. Gilson Inácio Wirth

Porto Alegre

2023

Eduardo Pellin Moser

## **Análise estocástica do comportamento elétrico de neurônios naturais e células ReRam**

Projeto de Diplomação II, apresentado ao Departamento de Engenharia Elétrica da Escola de Engenharia da Universidade Federal do Rio Grande do Sul, como requisito parcial para a obtenção do grau de Engenheiro Eletricista

BANCA EXAMINADORA

---

**Prof. Dr. Paulo Francisco Butzen**  
UFRGS

---

**Prof. Dr. Raphael Martins Brum**  
UFRGS

---

**Prof. Dr. Gilson Inácio Wirth**  
Orientador - UFRGS

Aprovado em 02 de Maio de 2023.

# Agradecimentos

Agradeço primeiramente a minha família, pelo apoio incondicional e estímulo durante todo meu período de graduação.

Ao meu orientador Gilson por toda a experiência e oportunidade que tive como membro de laboratório e orientado neste trabalho.

À banca por aceitar o convite e avaliar tudo que aqui foi construído.

Aos colegas da graduação, pois tenho certeza que todas as pedras que haviam em nossos caminhos foram menores quando estávamos em grupo.

A UFRGS por todas as experiências, felizes ou não, que passei nesta jornada que apenas a universidade federal poderia me proporcionar.

# Resumo

A computação neuromórfica é uma abordagem promissora para sistemas futuros de processamento de dados, com vantagens em termos de eficiência energética e capacidade de processamento devido sua arquitetura neuromórfica, que se baseia em redes de neurônios artificiais que operam de forma paralela e distribuída. Embora ainda em seus estágios iniciais de desenvolvimento, a pesquisa em computação neuromórfica tem avançado rapidamente nos últimos anos, explorando novas estruturas de hardware, como crossbars e unidades de processamento Multiply And Accumulate (MAC), muito utilizado nas aplicações da inteligência artificial, essas melhoram a eficiência e escalabilidade dos sistemas neuromórficos. Este projeto apresenta uma análise elétrica, focada em processos estocásticos, de três composições distintas de dispositivos Metal-Isolante-Metal (MIM) quanto a sua possibilidade de uso para construção de redes neurais que repliquem o funcionamento de um sistema nervoso central. Os dados experimentais de corrente em função do tempo sob diferença de tensão constante no dispositivo semiconductor foram coletados previamente no laboratório LCE da UFRGS e posteriormente analisados e comparados, através de algoritmos de MATLAB, com uma base de dados pública do comportamento resistivo em função do tempo de neurônios do cérebro de animais denominada "*Neural Signal Archive*". Ao comparar o crescimento da média da variância de corrente em células MIM submetidas a tensão constante e resistência em neurônios de ratos com injeção de corrente, conclui-se que há semelhança parcial no comportamento elétrico quando ambos estão submetidos a estímulo constante. Ao comparar o neurônio natural com diferentes injeções de correntes na mesma série temporal e as células MIM em tensão constante se obtém um crescimento semelhante da média de variância em função do tamanho da janela contemplada.

**Palavras-chave:** ReRam, Computação Neuromórfica, Memristores, .

# Abstract

Neuromorphic computing is a promising approach for future data processing systems, with advantages in terms of energy efficiency and processing capacity due to its neuromorphic architecture, which is based on networks of artificial neurons that operate in parallel and distributed. Although still in its early stages of development, research in neuromorphic computing has advanced rapidly in recent years, exploring new hardware structures such as crossbars and Multiply And Accumulate (MAC) processing units, widely used in artificial intelligence applications, these improve the efficiency and scalability of neuromorphic systems. This project presents an electrical analysis, focused on stochastic processes, of three different compositions of Metal-Insulator-Metal (MIM) devices regarding their possibility of use for the construction of neural networks that replicate the functioning of a central nervous system. Experimental current data as a function of time under constant voltage difference in the semiconductor device were previously collected at the LCE laboratory at UFRGS and subsequently analyzed and compared, through MATLAB algorithms, with a public database of resistive behavior as a function of time of neurons in the brain of animals called "Neural Signal Archive". When comparing the growth of the mean variance of current in MIM cells subjected to constant voltage and resistance in rat neurons with current injection, it is concluded that there is partial similarity in the electrical behavior when both are subjected to constant stimulation. When comparing the natural neuron with different injections of currents in the same time series and the MIM cells at constant voltage, a similar increase in the average variance is obtained as a function of the size of the contemplated window.

**Keywords:** ReRam, Neuromorphic Computing, Memristors

# Lista de Figuras

Figura 1 – Formação de diferentes filamentos condutores . . . . .	14
Figura 2 – Demonstração de parâmetros do RTN . . . . .	15
Figura 3 – Distribuição do tempo de captura e emissão em RTN . . . . .	15
Figura 4 – Representação elétrica de neurônio . . . . .	17
Figura 5 – Estrutura crossbar resistiva . . . . .	19
Figura 6 – Visualização gráfica da construção de camadas . . . . .	22
Figura 7 – Visualização gráfica das camadas de uma célula MIM de h-BN . . . . .	22
Figura 8 – Foto de amostras de células MIM de h-BN . . . . .	23
Figura 9 – Ampliação da figura 8 . . . . .	23
Figura 10 – Processos de SET e RESET com histerese $I \times V$ em amostras de $HfO_2$ .	24
Figura 11 – Processos de SET e RESET por tensão contínua em amostras de $TiO_2$	24
Figura 12 – Resistência de neurônio de rato em uma medida a esquerda, com o corte a direita . . . . .	28
Figura 13 – Média da variância conforme janelas de análise . . . . .	29
Figura 14 – Variância de segunda ordem dos dados analisados . . . . .	30
Figura 15 – Correlação cruzada de variância de células MIM e neurônimos . . . . .	31
Figura 16 – Correlação cruzada de variância em escala logarítmica . . . . .	32
Figura 17 – Resistência de neurônios de ratos . . . . .	33
Figura 18 – Média da variância conforme janelas de análise . . . . .	34
Figura 19 – Variância de segunda ordem dos dados analisados . . . . .	35
Figura 20 – Correlação cruzada de variância de células MIM e neurônimos . . . . .	37

# Lista de Tabelas

Tabela 1 – Média da variância das bases de dados em função do tamanho da janela em análise . . . . .	28
Tabela 2 – Variância da média de variâncias em amostras . . . . .	29
Tabela 3 – Valores de curtose para variância de segunda ordem em mesma série temporal . . . . .	30
Tabela 4 – Valores de correlação cruzada de variância entre células MIM e neurônios de ratos . . . . .	31
Tabela 5 – Média da variância em função do tamanho da janela analisada em série temporal única . . . . .	33
Tabela 6 – Variância da média de variâncias em amostras para série temporal única	34
Tabela 7 – Valores de curtose para variância de segunda ordem . . . . .	35
Tabela 8 – Valores de correlação cruzada de variância entre células MIM e neurônios de ratos em mesma série temporal . . . . .	36



# Lista de abreviaturas

RTN	Randon Telegraph Noise
MIM	Metal-Isolante-Metal
LRS	Low Resistance State
HRS	High Resistance State
LCE	Laboratório de caracterização elétrica
CPU	Central Processing Unit
ML	Machine Learning
AI	Artificial Inteligence
DNN	Deep Neural Network
MVM	Matrix-Vector Multiplication
MAC	Multiply and Accumulate
NSA	Neural Signal Archive

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>10</b>
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA E REVISÃO BIBLIOGRÁFICA</b>	<b>12</b>
2.1	Chaveamento Resistivo	12
2.2	Formação de filamento condutivo em células MIM	13
2.3	Ruido aleatório de telegrafo (RTN)	14
2.4	Caracterização elétrica do neurônio	16
2.5	Arquitetura Von Neumann e gargalo	17
2.6	Estrutura "Cross bar" e processamento MAC	18
<b>3</b>	<b>METODOLOGIA</b>	<b>21</b>
3.1	Aquisição de dados	21
3.1.1	Amostras	21
3.1.2	Medidas	21
3.2	Medidas em neurônios do sistema nervoso central	25
3.3	Comparação da caracterização elétrica de neurônios e células MIM	26
<b>4</b>	<b>RESULTADOS</b>	<b>27</b>
4.1	Variância das medidas	27
4.2	Variância com estímulos diferentes em série temporal	32
<b>5</b>	<b>CONCLUSÕES</b>	<b>38</b>
5.1	Trabalhos futuros	39
5.2	Contribuição científica	39
	<b>REFERÊNCIAS BIBLIOGRÁFICAS</b>	<b>40</b>

# 1 Introdução

A computação neuromórfica tem por objetivo criar um sistema de sinapses eletrônicas que seja capaz de processar dados apresentando o mesmo comportamento físico que o sistema nervoso central apresenta quando pensamos. Seu avanço pode fazer com que superemos limitações fundamentais do processamento computacional e processamento de dados como conhecemos atualmente. Não há hoje, a caracterização de um dispositivo que consiga representar uma sinapse de maneira analógica e os sistemas digitais não são fidedignos devido ao comportamento padrão binário, que não serve para representar um sistema que necessita operar entre diversos valores.

Os neurônios do sistema nervoso central apresentam um chaveamento resistivo no comportamento em função do tempo, em que ocorre mudança abrupta no valor de resistência e assim o volume da passagem de corrente se altera conforme os níveis dessa resistência chaveada. Esse fenômeno ocorre devido a possibilidade das sinapses de adquirir íons  $\text{Ca}_2$  ou  $\text{Na}_2$  liberados pela passagem de impulsos elétricos dos neurônios e então gerando uma alteração do campo elétrico e assim uma alteração da resistência equivalente pela presença de um íon em um sistema elétrico de escala micrométrica. Para replicar o comportamento analogicamente, aposta-se em semicondutores que apresentem um comportamento que consiga alternar a resistência entre níveis, sejam eles bem definidos ou não.

Para simular redes neurais artificiais com o princípio de funcionamento do cérebro de comutação resistiva, se utiliza dispositivos de acesso de memória aleatória e entre os testados os memristores, estruturas resistivas capazes de se alterar conforme a situação elétrica que são submetidas e assim armazenar informação sem demanda de energia posterior a sua alteração, alcançaram desempenho mais interessante devido seu baixo consumo de energia e grande capacidade de processamento comparada a estruturas que utilizam transistores como as atuais. Os dispositivos Metal-Isolante-Metal (MIM) são construídos com diversas combinações de materiais sendo sempre uma camada metálica, uma fina camada isolante e outra camada metálica. Submetendo então esse dispositivo a uma tensão contínua em um curto período de tempo, forma-se um filamento condutivo instável na camada isolante devido sua curta espessura e baixa rigidez, assim pequenas quantidades das camadas de metais se rearranjam e possibilitam uma passagem de corrente em valores mais altos e colocam o dispositivo em análise em um estado de baixa resistência do inglês "Low Resistance State"(LRS). O componente pode voltar ao estados de alta resistência (HRS) conforme se submete o dispositivo a um processo oposto com tensão contínua em polaridade oposta à que o colocou em baixa resistência. Devido o arranjo pequeno de material condutivo nesse filamento "forçado", a passagem de corrente é alterada

pelo campo elétrico de moléculas do material isolante carregadas com algum elétron preso em sua estrutura. Desta forma a área em que o campo elétrico do íon atua pode cobrir todo o filamento condutor e assim diminuir muito a capacidade da passagem de corrente assim alterando o valor total da resistência. Quando o elétron se desprende, o dispositivo volta às características elétricas que apresentava antes da molécula estar carregada, assim alternando valores de resistência equivalente como em um chaveamento resistivo. Denomina-se estas moléculas que podem ou não estar ocupadas com um elétron de "Traps", ou em português, armadilhas. A aleatoriedade do processo faz com que múltiplas armadilhas possam ocorrer no dispositivo e assim causar chaveamento entre mais de um nível, desta forma o comportamento de ruído de telégrafo aleatório (RTN - Random Telegraph Noise) é estudado pela ciência como um forte candidato para a computação neuromórfica.

O desenvolvimento da computação inspirada no cérebro representa uma nova arquitetura de sistema com potencial para executar tarefas complexas rapidamente e com consumo de energia reduzido em relação aos sistemas atuais. Uma vez alcançando um sistema computacional com esta premissa, poderemos construir máquinas com reconhecimento de padrões e aprendizado de sequências associativas, estas não viáveis em nossos sistemas atuais.

Neste projeto, pretende-se verificar a possibilidade da reprodução do comportamento neural em inteligência artificial com os dispositivos MIM estudando os arranjos atômicos conforme o chaveamento. Com os resultados da análise pode ocorrer uma grande simplificação da estrutura de hardware necessária para projetar circuitos de computadores neuromórficos. O estudo será realizado com as medidas de dispositivos MIM de dióxido de titânio ( $\text{TiO}_2$ ), Óxido de Háfênio ( $\text{HfO}$ ) e Nitreto de Boro Hexagonal (HBN) realizadas no laboratório de caracterização elétrica (LCE) da UFRGS.

Foi realizada uma análise estatística do comportamento elétrico de neurônios naturais e dispositivos MIM, visando identificar semelhanças e diferenças nas séries temporais medidas em laboratório células MIM e séries temporais medidas em neurônios naturais disponíveis publicamente. Em cenário de estímulo constante nos dois tipos de célula obteve-se uma semelhança parcial devido ambas terem crescimento constante porém não obedecendo o mesmo formato de curva ao comparar a variância média com múltiplas quantidades de pontos usados no cálculo da média. Quando realizados os mesmos cálculos porém com múltiplos níveis de estímulo elétrico para os neurônios naturais e tensão constante para as células MIM os formatos de curva foram mais semelhantes que no teste anterior pois ambos crescem com formato de sigmoide quando dispostos graficamente com eixo X em escala logarítmica.

## 2 Fundamentação Teórica e Revisão Bibliográfica

### 2.1 Chaveamento Resistivo

O chaveamento resistivo na nanoeletrônica é considerado a propriedade demonstrada em material que possuem uma mudança cíclica de sua resistividade elétrica entre níveis estáveis conforme submetido a um estresse elétrico (IELMINI; WASER, 2015). O componente é então denominado de memristor ou memória resistiva ou até RRAM (Resistive Random Access Memory) de memória de acesso aleatório resistiva (IELMINI; WASER, 2015). Estes dispositivos apresentam em sua grande maioria a estabilidade em dois estados possíveis, sendo eles o de alta resistência e baixa resistência, respectivamente "HRS" e "LRS". Alguns casos de configurações com materiais específicos também apresentam múltiplos níveis programáveis e estáveis porém a distinção entre os possíveis estados do componente é mais trabalhoso devido a variabilidade inerente das magnitudes elétricas do componente em abruptas mudanças de valor de corrente ou tensão (LANZA *et al.*, 2019).

Células MIM com chaveamento resistivo consistem em uma promissora aposta para superar as barreiras da lei de Moore em um cenário pós alcançar o máximo de extração da tecnologia CMOS. Sua descrição física consiste em um isolante que apresente propriedade de chaveamento resistivo entre dois eletrodos condutores orientados como um de topo e outro de base. Para a função de isolante é possível escolher entre diversas matérias conhecidas que apresentam esse comportamento elétrico, entretanto, os de maior destaque são: óxidos de metais de transição como dióxido de titânio, os quais são comumente usados como anodo em baterias alcalinas por apresentar abundantes sites ativos curto caminho de difusão, baixo custo de preparação e alta capacidade teórica (MOULSON, 1991); calcogenetos como sulfeto de cobre; materiais 2-D como nitreto de boro hexagonal e entre outros (WONG *et al.*, 2012)(SAKAMOTO *et al.*, 2003)(SHI *et al.*, 2018). Quanto aos materiais metálicos dos eletrodos são normalmente compostos por metais como platina, ouro, prata, cobre, níquel, titânio (LANZA *et al.*, 2019)(CHEN *et al.*, 2015). O substrato usado para depositar os materiais deve ter baixa rugosidade para evitar grandes mudanças de características entre amostras do mesmo componente como um wafer de silício oxidado (LANZA *et al.*, 2019).

## 2.2 Formação de filamento condutivo em células MIM

O comportamento de chaveamento resistivo em dispositivos MIM é demonstrado conforme a formação de um filamento condutivo instável na camada isolante. As amostras contempladas nesse estudo operam de forma bipolar partindo de um estado de alta resistência (HRS) onde se aplica uma diferença de tensão entre os terminais, sendo uma tensão superior no terminal de topo e uma inferior no de base, que supera a tensão de limite do dispositivo e assim o coloca no estado de baixa resistência (LRS). Este processo é denominado de "*SET*". Para evitar possíveis desgastes e danos ao componente é colocado um limite de corrente para evitar altas potências dissipadas no semicondutor durante esse processo. O processo reverso de levar o dispositivo em LRS para HRS é possível a partir de uma inversão da polaridade das tensões utilizadas em que o terminal de base teria uma tensão superior ao terminal de topo e também um maior valor absoluto entre os terminais, tendo assim um fluxo contrário de corrente em relação ao processo que o levou para baixa resistência e causando a dissolução do filamento condutivo. Este processo é denominado "*RESET*".


Células feitas de óxidos de metais de transição apresentam o filamento condutor formado pelos ânions, no caso de de oxigênio, do material isolante. Essa mudança é denominada de mudança de memória de valência. A migração de partículas de cátion do mesmo material também também é possível e contribui para a alteração do valor da resistência no chaveamento resistivo (WEDIG *et al.*, 2016)

Em células compostas por um terminal de metal eletro quimicamente ativo e o terminal de contraparte inerte divididos pelo isolante com propriedades de chaveamento, o processo de formação de filamento condutor é dado pela movimentação de células de metal ativo em direção ao inerte. Este outro processo chama-se metalização eletroquímica. Durante o ciclo de "*SET*" o componente parte do modo de HRS e a partir de reações de dissolução anódica do terminal com tensão positiva, isso é, da liberação de elétron do metal e assim a formação de um cátion e ocorre a movimentação deste mesmo íon para uma menor distância do terminal oposto pela força do campo elétrico gerado pela tensão aplicada. Conforme o tempo mais material é desprendido e o filamento começa a se tornar longo o suficiente para realizar contato elétrico direto entre os dois terminais e assim consolidar o modo LRS e possibilitar uma maior passagem de corrente pelo dispositivo no caminho ainda instável pela forte atuação do campo elétrico de íons próximos dos elétrons em movimentação. É possível realizar a dissolução deste mesmo processo pelo "*RESET*", o qual retorna as moléculas a sua posição original porém sempre com um maior estresse e desgaste do material (VALOV *et al.*, 2011).

A figura 1 demonstra 3 diferentes situações de formação de filamento em dispositivos MIM. Mais a esquerda da imagem, há a representação de uma formação de filamento por metalização eletroquímica em um dispositivo composto por eletrodos de Cobre e Platina e

um óxido de háfnio como isolante. A figura central demonstra uma célula com o mesmo isolante porém dois terminais compostos por Platina e assim uma formação por mudança de memória de valência. A direita uma formação de filamento com um pouco dos dois processos possíveis em uma célula de eletrodos de Titânio e Cobre e substrato de nitreto de Boro hexagonal.

Figura 1 – Formação de diferentes filamentos condutores



Fonte: SHI, *et al.*, 2018

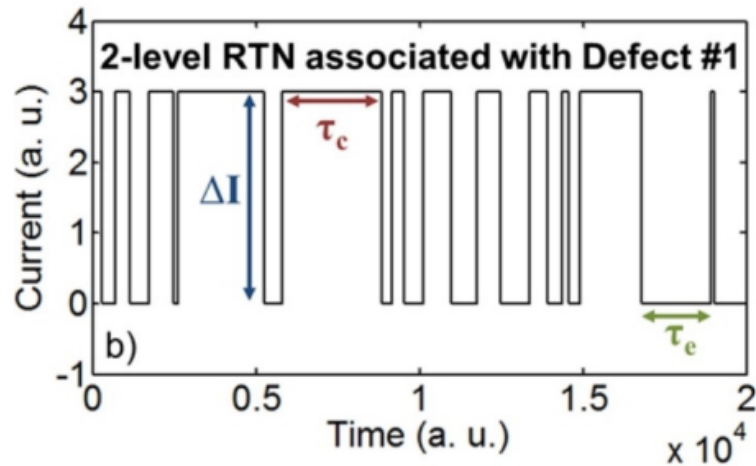
## 2.3 Ruído aleatório de telegrafo (RTN)

O RTN na tecnologia MOSFET é uma alternância temporária na corrente de dreno do componente entre níveis bem definidos. A explicação do evento se dá pelo efeito do campo elétrico de um elétron acoplado temporariamente a uma denominada "armadilha" que consiste em um defeito na interface de Silício ou no óxido próximo a camada de inversão (FLEETWOOD, 1992). Estudos mais aprofundados na ocorrência foram essenciais para compreender a confiabilidade em circuitos integrados que apresentem esses defeitos (SIMOEN; CLAEYS, 2016).

A caracterização do comportamento do RTN pode ser descrita entre 3 parâmetros essenciais, são eles: amplitude entre os níveis de flutuação da corrente ( $\Delta I$ ); tempo médio de emissão da carga no defeito ( $\tau_e$ ) e o tempo de captura do defeito ( $\tau_c$ ). Os efeitos são exemplificados na Figura 2 (PUGLISI *et al.*, 2017) onde a variação da corrente é demonstrada pela amplitude da movimentação tal qual mostrando o impacto daquele defeito na resistência total do dispositivo, o tempo de captura como o intervalo em que a


corrente se mantém em nível elevado e o de emissão o intervalo que a mesma se mantém em baixo módulo. Estudos demonstram que os tempos analisados de captura e emissão das cargas demonstram uma distribuição exponencial, assim um processo de Poisson, devido a natureza estocástica do comportamento físico dos defeitos (KIRTON; UREN, 1989). A Figura 3(KIRTON; UREN, 1989) demonstra uma destas distribuições.

Figura 2 – Demonstração de parâmetros do RTN



Fonte: PUGLISE *et al.*, 2017

Figura 3 – Distribuição do tempo de captura e emissão em RTN



Fonte: KIRTON; UREN, 1989



## 2.4 Caracterização elétrica do neurônio

A resistência elétrica de um neurônio é influenciada pela presença de canais iônicos em sua membrana celular, os quais controlam o fluxo de íons através da membrana e, conseqüentemente, afetam a resistência elétrica. Durante o potencial de repouso de um neurônio, a membrana celular apresenta uma resistência elétrica relativamente alta devido à presença de canais iônicos que impedem a passagem de íons através da membrana (HODGKIN; HUXLEY, 1952). No entanto, quando um neurônio recebe um estímulo adequado, os canais iônicos voltagem-dependentes na membrana celular se abrem, permitindo que os íons fluam através da membrana e alterem a resistência elétrica do neurônio (HILLE, 2001).


Se os canais iônicos abertos permitem a entrada de íons positivos na célula (como sódio ou cálcio), a resistência elétrica do neurônio diminui, permitindo que a corrente elétrica flua com mais facilidade. Isso pode levar a um potencial de ação, que é uma mudança rápida e temporária na polaridade elétrica da membrana celular que permite a transmissão de informações ao longo do neurônio (KANDEL *et al.*, 2013).

Por outro lado, se os canais iônicos abertos permitem a saída de íons positivos da célula (como potássio), a resistência elétrica do neurônio aumenta, dificultando a passagem da corrente elétrica. Isso pode levar à hiperpolarização da célula, o que significa que o potencial elétrico da membrana se torna mais negativo do que o potencial de repouso e torna mais difícil a geração de um potencial de ação (KANDEL *et al.*, 2013).

A relação entre corrente e tensão em um neurônio pode ser negativa porque os neurônios não são componentes elétricos passivos como resistores. Em vez disso, são componentes ativos que geram sua própria atividade elétrica através da abertura e fechamento de canais iônicos na membrana celular. Quando um neurônio recebe uma corrente de entrada, isso pode causar alterações no fluxo iônico através da membrana, o que pode resultar em mudanças no potencial de membrana. A relação entre a corrente de entrada e a mudança resultante no potencial de membrana é descrita usando o conceito de resistência de entrada, que é a razão entre a mudança no potencial de membrana e a corrente injetada (HODGKIN; HUXLEY, 1952).

Em resumo, a resistência elétrica de um neurônio é dinâmica e é controlada pelos canais iônicos presentes em sua membrana celular, os quais podem se abrir ou fechar em resposta a estímulos externos. Isso permite que os neurônios modifiquem sua atividade elétrica em tempo real para processar e transmitir informações pelo sistema nervoso. A figura 4 mostra uma representação elétrica de um neurônio.

Figura 4 – Representação elétrica de neurônio



Fonte: HODGKIN; HUXLEY, 1952

## 2.5 Arquitetura Von Neumann e gargalo

A computação tradicional é baseada na arquitetura Von Neumann, onde a informação e as instruções são armazenadas em uma única memória (EIGENMANN; LILJA, 1998), logo a informação é processada e posteriormente armazenada na memória do computador. Essa transmissão acaba acarretando em uma limitação fundamental do desempenho das máquinas devido ao atraso à memória de acesso (ARIKPO; OGBAN; ETENG, 2007), comumente chamada de "Gargalo de Von Neumann". A memória requer um intervalo para gravar os dados processados o que depende da velocidade de gravação da tecnologia usada na construção desta memória, sendo assim não é possível seguir constantemente com o processamento que fica ocioso neste período. Ocorre também que a melhoria das tecnologias de CPU com aumento de velocidade usando pipelines, ocorre num ritmo mais veloz que os avanços em tecnologias de memórias (ARIKPO; OGBAN; ETENG, 2007). Essa diferença acarreta em um desequilíbrio cada vez mais presente na diferença de performance entre esses dois componentes essenciais da computação, onde o mais lento entre eles vai ditar a performance máxima da máquina.

Para reduzir a limitação do gargalo se utiliza a memória Cache nos processadores, memória essa fisicamente mais próxima à CPU e utilizada apenas para alocação de dados temporários essenciais para o decorrer do processamento em questão (SMITH, 1982). Seu princípio de funcionamento é diminuir o tempo médio de acesso do processador às instruções e dados, porém sua capacidade é limitada e para grandes armazenamentos é necessário utilizar a memória principal do computador. Os computadores apresentam diferentes níveis de memória cache sendo o primeiro nível, L1, o de maior velocidade


estando fisicamente dentro do processador e contendo os dados de mais frequente acesso porem com menor capacidade de armazenamento, enquanto o segundo e terceiro nível, respectivamente L2 e L3, ja se encontram fora do processador e com mais capacidade porem menos velocidade de acesso (ALSHAREF *et al.*, 2021). O contraponto desta abordagem é o alto consumo de energia para manter maior uso da memória cache, custo elevado e perda de velocidade conforme a expansão da capacidade desta memória (ALSHAREF *et al.*, 2021).

## 2.6 Estrutura "Cross bar" e processamento MAC

O avanço rápido de aprendizado de máquina, do inglês "*Machine learning*", e inteligencias artificias vem impactando fortemente a vida humana no decorrer da ultima década com o avanço de suas aplicações (SILVER *et al.*, 2017). Algoritmos de inteligencia artificial, especialmente redes neurais profundas (DNNs), têm obtido sucesso notável em diversas aplicações, como classificação de imagem, processamento natural de linguagem e detecção de objeto (LECUN; BENGIO; HINTON, 2015). Essas aplicações têm impulsionado o avanço da área de aprendizado de maquina nos últimos anos, além de contribuir para a solução de diversos problemas práticos em áreas como saúde, transporte, segurança e entretenimento. Infelizmente a capacidade de aplicações mais complexas, como as de aprendizado profundo, requer uma complexidade de processamento também elevada o que em diversas situações acarreta em um funcionamento mais lento ou custoso do que o desejado (XU *et al.*, 2018). Tentativas já foram propostas para melhorar a performance de tempo e energia despendidos no processamento destes algoritmos de DNN com base em aceleradores, projetados para a rápida capacidade de realizar multiplicações de matriz-vetor, da sigla original MVM, e kernel computacional dedicado a aplicação (CHAKRABORTY *et al.*, 2020). Eventualmente ocorre a limitação por gargalo pois estes aceleradores ainda utilizam de memória externa ao processador (WULF; MCKEE, 1995), sendo essa limitação apenas atenuada com uma maior proximidade entre processador e memória para futuras arquiteturas computacionais.

As estruturas "*Crossbar*" resistivas são construções bidimensionais compostas por fios interseccionados e conectados por um material resistivo representada na figura 5. A operação chave que esta estrutura realiza é a multiplicação de matriz-vetor (MVM), que é um componente fundamental de muitos algoritmos de "*machine learning*" (CHAKRABORTY *et al.*, 2020). Em um "*Crossbar*", as linhas e colunas da estrutura representam os vetores de entrada e saída da matriz, respectivamente, e o material resistivo em cada intersecção serve como um peso ou multiplicador para o elemento correspondente na matriz.

Figura 5 – Estrutura crossbar resistiva



Fonte: CHAKRABORTY *et al.*, 2020

O material resistivo utilizado em um "Crossbar" pode ser constituído por diferentes compostos, como óxidos metálicos ou óxidos de transição. Este material pode ser programado ou ajustado para modificar os pesos da matriz (CHAKRABORTY *et al.*, 2020). A estrutura de "Crossbar" apresenta diversas vantagens como uma plataforma de hardware para "machine learning", tais como baixo consumo de energia, alta velocidade e escalabilidade.

Há uma grande possibilidade de progresso tecnológico levando em consideração os estudos de design e avaliação de aceleradores de hardware baseados em "Crossbars" resistivos para redes neurais profundas. O uso de "Crossbars" resistivos como plataforma de hardware para aprendizado de máquina pode oferecer vantagens como baixo consumo de energia e alta velocidade, além de permitir o processamento de grandes volumes de dados (OHNO *et al.*, 2020). A abordagem também permite uma alta densidade de armazenamento e escalabilidade do sistema, permitindo então sistemas de computação neuromórfica com alta eficiência (CHAKRABORTY *et al.*, 2020). Para maximizar os resultados da inteligência artificial construída a partir desta técnica seria necessário desenvolver uma série de algoritmos e técnicas de treinamento compatíveis com a computação analógica utilizando estas estruturas "crossbar" (XIA; YANG, 2019). Porém, ainda existem desafios para a implementação desta abordagem como a precisão limitada dos pesos em um "Crossbar" devido o comportamento não ideal do material resistivo, que pode levar a erros de aproximação e redução da precisão nos modelos de "machine learning" (OHNO *et al.*, 2020).

Com base nas correntes que percorrem a estrutura "*Crossbar*", se realiza um processo de multiplicação e acumulo (MAC) da tensão "V" em cada entrada e as respectivas condutâncias "G" conectadas a essas entradas. Como demonstrado na figura 5. Essa computação permite que operações de MVM paralelo tenham V e G como entradas do sistema enquanto a saída seria a corrente  $I_j$  da matriz na estrutura "*Crossbar*" (CHAKRABORTY *et al.*, 2020). Esse processo MAC realizado por meio das correntes que percorrem a estrutura "*Crossbar*" permite realizar operações de MVM paralelo de forma eficiente. Essa técnica é fundamental para o desempenho de sistemas de "*Machine learning*" baseados em "*Crossbar*" resistivos, já que as operações MVM são frequentemente utilizadas em algoritmos de aprendizagem de máquina (CHAKRABORTY *et al.*, 2020). Além disso, a utilização de "*Crossbar*" resistivos para a realização de operações MVM paralelo pode oferecer vantagens como alta velocidade de processamento e baixo consumo de energia, tornando essa tecnologia promissora para aplicações em inteligência artificial e computação neuromórfica.

## 3 Metodologia

Para a construção de um sistema neuromórfico de computação é necessário primeiramente de um componente capaz de reproduzir o comportamento elétrico de um neurônio do sistema nervoso central em função do tempo. Devido o comportamento estocástico dos neurônios é de estrema importância comparar estatisticamente a semelhança do dispositivo MIM utilizado neste estudo e os neurônios em funcionamento normal. Para tal uma série de medidas foram coletadas desta amostras bem como testes de comparação foram planejados para averiguar as então semelhanças e talvez pontos a serem contornados para futuros projetos de construção de sistemas analógicos utilizando o componente.

### 3.1 Aquisição de dados


#### 3.1.1 Amostras

O LABPROT da UFRGS possui amostras de células MIM fabricadas no "*The Institute of Functional Nano & Soft Materials*" da Universidade de Soochow, China, para pesquisas no tema. Elas são compostas com camadas de Ni/TiO<sub>2</sub>/Au, Ni/HfO<sub>2</sub>/Au e Ni/h-BN/Au com área ativa de contato de  $5\mu\text{m} \times 5\mu\text{m}$ . O processo de fabricação é descrito conforme (LI *et al* 2021; SHI *et al* 2018) Um substrato de  $1.5\text{cm} \times 1.5\text{cm}$  de SiO<sub>2</sub> são higienizados com álcool, acetona e água deionizada com um processo de sonicação de 20 minutos cada parte do processo. Então se deposita com fotolitografia e deposição metálica por evaporação via feixe de elétrons o eletrodo de base com Au de 40nm de espessura com uma pequena camada de 10nm de Ti para fixação no substrato. Posteriormente os respectivos isolantes são depositados, sendo TiO<sub>2</sub> e HfO<sub>2</sub> o mesmo processo de deposição de camada atômica com cerca de 4nm de espessura final, para h-BN a camada é sintetizada com deposição de vapor químico em uma lamina de Cu e então transferida para cobrir o eletrodo de base, possui 6nm de espessura. Finalmente é depositado o eletrodo de topo com 50nm de espessura de Ni via fotolitografia e crepitação. A figura 6 demonstra uma representação visual das camadas separando substrato, terminais e dielétrico em um dispositivo com h-BN enquanto a figura 7 demonstra graficamente cada material lateralmente nas camadas da mesma amostra. As figuras 8 e 9 demonstram visualmente como são amostras utilizadas neste trabalho.

#### 3.1.2 Medidas


Este estudo foi contemplado com a possibilidade de realizar a caracterização elétrica delas no LCE (UFRGS) onde ocorreram diversas medidas de análise de corrente

Figura 6 – Visualização gráfica da construção de camadas



Fonte: Schematic Produced by the Institute of Functional Nano & Soft Materials at Soochow University


Figura 7 – Visualização gráfica das camadas de uma célula MIM de h-BN



Fonte: adaptado de Li, Xuehua (2020)


em função do tempo após o SET em diferentes tensões de leitura. Primeiramente a célula era posicionada a uma estação de sonda conectada a um analisador de parâmetros de semicondutores Agilent 4156A, baixavam-se as ponteiros Cascade microtech EP6 nos eletrodos de topo e e então colocada em LRS com o processo de SET, realizados tanto com um processo de curva de histerese IxV quanto um curto período de tensão contínua entre os dois terminais. A resolução da medição para o analisador é de 1 fA para medidas de corrente, e de 0.2  $\mu$ V para as medidas de tensão. No método de curva de histerese uma crescente, e em seguida decrescente, tensão de corrente contínua é aplicada entre os dois terminais e o componente se alterna para o modo LRS conforme a formação do filamento condutor, e podemos observar uma mudança em que valores mais altos de corrente aparecem em tensões menores na volta, valor esse limitado sempre para o valor de "compliance" definido no analisador de parâmetros para não submeter a amostra a carargas excessivas. Quanto a formação de filamentos por tensão contínua era colocado também um limite para a corrente para evitar danos e simplesmente se submetia a mostra a um período de tempo com tensão contínua de cerca de 3V aplica entre seus terminais, observava-se a modo LRS quando a corrente também atingia o seu valor limite para

Figura 8 – Foto de amostras de células MIM de h-BN



Fonte: Li, Xuehua (2020)

Figura 9 – Ampliação da figura 8




Fonte: Li, Xuehua (2020)

a mesma tensão que antes apresentava baixas correntes. Para retornar as amostras ao modo HRS pela realização do RESET era usado o processo idêntico aos de SET trocando polaridade da tensão para ser negativa no eletrodo de topo e aterrada ao de base. As figuras 10 e 11 demonstram ambos os processos descritos de SET e RESET, sendo a figura 10 a histerese em uma medida de  $HfO_2$  e a figura 11 um processo de tensão contínua em uma amostra de  $TiO_2$ , ambas coletadas em laboratório para a elaboração desta e outras pesquisas. Posteriormente eram realizadas medidas com tensões constantes partindo




de 100mV no eletrodo de topo e aterramento no de base de uma amostra selecionada e conforme os resultados do RTN observado e do valor da corrente se baixava a alimentação no terminal superior para 50mV ou aumentando para 200mV para evitar altas potencias no componente e assim evitar danos. O tempo da medida variava conforme a frequência de aquisição utilizada. Era selecionada conforme a atividade dos Traps em análise para ter maior detalhe em altas frequências e assim menores janelas de tempo ou maiores intervalos de aquisição para observar mais transições em Traps de atividade mais lenta. Todas as medidas foram realizada em ambiente escuro, temperatura da sala e pressão atmosférica ambiente. Desta forma ao fim da aquisição se possuía 151 medidas de RTN de Dióxido de Titânio, 83 de Óxido de Háfnio e 110 de Nitreto de Boro Hexagonal, todas com seus tempos de acordo com as características do material. Todas as medidas possuem um total de 10001 pontos que é a resolução máxima de uma medida do equipamento Agilent 4156A disponível no laboratório.

Figura 10 – Processos de SET e RESET com histerese IxV em amostras de HfO2



Fonte: Becker, 2022

Figura 11 – Processos de SET e RESET por tensão contínua em amostras de TiO2



Fonte: Becker, 2022

## 3.2 Medidas em neurônios do sistema nervoso central

Posteriormente foi procurada uma base de dados de utilização pública de comportamento elétrico por tempo de apenas um neurônio por medida. Encontrou-se a base "The Neural Signal Archive - A neuro-informatic resource for scientists" que dispõe de diferentes tipos de testes de caracterização elétrica em neurônios de ratos e macacos. Entre as metodologias de testes disponíveis se escolheu por semelhança à metodologia aplicada na coleta de dados do LCE, uma base de dados que demonstra a resposta em tensão de um neurônio de rato a um estímulo de injeção de corrente em função do tempo.

Dentre os *datasets* disponíveis no site, foi escolhida a *nsa2004.5 Voltage vs. level of injected current in slice*, base que dispõe de medidas de 560 ms capturados a uma frequência de 5 kHz totalizando 2800 pontos por medida. Seus aquisições foram feitas com 5 amostras diferentes de neurônios em se conseguiu um total de 77 medidas. Foi feita com neurônios do córtex de *Rattus norvegicus* pela universidade de Nova York pelos pesquisadores HYSELL OVIEDO e ALEX D. REYES em 2002. Nela Para realizar a aquisição de dados, os pesquisadores primeiramente anestesiaram os ratos e removeram seus cérebros, mantendo-os em uma solução que permitiu a perfusão com oxigênio e nutrientes. Em seguida, eles cortaram fatias finas do córtex cerebral, que foram mantidas em uma câmara de gravação de células inteiras. Durante a realização dos experimentos, os neurônios foram mantidos em uma solução com temperatura e pH controlados para preservar sua viabilidade e funcionalidade. Para estimular os neurônios, os pesquisadores utilizaram um eletrodo de vidro microfabricado, que permitiu a aplicação precisa de estímulos nas dendrites dos neurônios. Eles aplicaram tanto estímulos assíncronos quanto síncronos em diferentes locais das dendrites dos neurônios e registraram a resposta dos neurônios em termos de potencial de membrana e taxa de disparo de ação. Esses estímulos elétricos foram injeções de corrente. Os dados foram coletados usando amplificadores eletrofisiológicos e digitalizados em um computador para posterior análise. A análise envolveu a identificação de picos de atividade do neurônio e o cálculo da taxa de disparo em resposta aos diferentes estímulos aplicados. é injetada um valor constante de corrente 30 ms após o início da medida e com duração de 500 ms, os valores mudam conforme a medida. Cada neurônio teve seus testes em sequencia com um intervalo de 3 segundos entre medidas mantendo o *setup* para garantir mesmas condições com a penas o estímulo diferindo entre elas.

Neste estudo concluiu-se que a entrada sincronizada e assíncrona para os dendritos de neurônios piramidais pode aumentar significativamente a taxa de disparo neuronal (OVIEDO; REYES, 2002). Além disso, os autores destacam a importância do *timing* da entrada para a eficácia da ativação dendrítica, com entradas síncronas causando grandes transientes de tensão e entradas assíncronas produzindo uma despolarização mais constante.

### 3.3 Comparação da caracterização elétrica de neurônios e células MIM

Para realizar comparação entre as duas fontes provenientes de dados serão escritos algoritmos utilizando a ferramenta "Matlab" para cada característica que se desejava comparar. Primeiramente as medidas de tensão sob tempo da NSL para resistência em função do tempo visto que diferentes valores de corrente foram utilizados. Para os dados coletados em laboratório foi feita a análise da variância da resistência do componente em diferentes janelas recortadas na medida. Neste, devido ao número de pontos máximo da NSA, se limitou as medidas de 10001 pontos em cortes de 2800 pontos. Estas então foram cortadas no máximo de seções possíveis de mesma quantidade de pontos e assim calculado a variância da janela e assim realizado uma média entre todas as janelas analisadas. A quantidade de pontos analisadas variou então entre 2 e 2048. O mesmo processo foi aplicado para as medidas da NSL para comparação. No caso de similaridade entre essas medidas e os neurônios saberemos que a variação de valor de resistência dos dois elementos comparados tem uma relação semelhante de curto e longo prazo de análise, sendo assim uma confirmação da semelhança do seu comportamento e um passo mais próximo da confirmação de suas semelhanças estocásticas.

## 4 Resultados


### 4.1 Variância das medidas

Após as coletas de dados em laboratório e pesquisa por base de dados contendo análise de um neurônio em função do tempo por amostra, foi realizada a comparação da média de variância das medidas conforme uma janela de amostras analisada. Foram usados para cálculo números de amostra que crescem exponencialmente a partir da base 2 até o máximo de 2048 pontos contemplados nas medidas. O valor foi escolhido devido a limitação da base de dados encontrada que tinha no máximo 2800 pontos. Foi calculada também a média da variância para janelas de 4096 e 8192 pontos para as amostras de células MIM devido suas maiores janelas máximas.

Visto que a base de dados "*Neural Signal Archive*" originalmente apresenta a resposta em tensão de um estímulo fixo de corrente em neurônio, com diferentes valores por medida, foi então feita a conversão de todos os valores da base de dados para resistência do neurônio nesse período. No total a base possui então 77 medidas de 5 amostras de neurônios diferentes. Foi feito também um corte nos dados visto que as medidas originalmente possuem 2800 pontos e a análise seriam com crescimento de janela exponencial em base 2, portanto os momentos em que as amostras não estavam submetidas a estímulo elétrico foram desconsideradas simetricamente, logo, excluindo 376 pontos do início e do final das medidas afim de chegar aos 2048 pontos necessários para a análise. Este corte permite que análise seja feita apenas em momentos onde a amostra esta submetida a estímulo elétrico durante toda a janela, visto que cada medida começa 30 ms antes do estímulo e termina também 30 ms após seu término, sendo assim os 376 pontos cortados são mais que o dobro dos 150 pontos medidos sem corrente injetada no início e fim da medida. Um exemplo da medida de resistência do neurônio de rato em função da amostra da NSA se encontra com e sem o corte descrito na figura 12.

Ao comparar as variâncias das bases de dados "*Neural Signal Archive*" e da medidas coletadas de células MIM em laboratório em janelas de análise crescendo exponencialmente com base 2 obtém-se os seguintes resultados dispostos na tabela 1. Dispondo os resultados lado-a-lado em suas respectivas escalas obtém-se então o gráfico na figura 13.

Figura 12 – Resistência de neurônio de rato em uma medida a esquerda, com o corte a direita



Fonte: O Autor, 2023


Tabela 1 – Média da variância das bases de dados em função do tamanho da janela em análise

Janela de amostragem	Célula MIM ( $A^2$ )	Neurônio de Rato ( $M\Omega^2$ )
2	1.66 E-13	63.88
4	2.09 E-13	104.96
8	2.65 E-13	156.91
16	3.54 E-13	184.09
32	5.16 E-13	212.90
64	7.56 E-13	255.30
128	1.16 E-12	303.60
256	1.52 E-12	321.37
512	2.20 E-12	325.20
1024	2.89 E-12	326.41
2048	8.56 E-12	326.60

Fonte: o Autor, 2023.

A variância de segunda ordem também foi calculada afim de verificar a taxa de variação da variância e se ocorre de fato uma relação semelhante com a janela de amostragem em questão. Os resultados estão dispostos na tabela 2 e colocados graficamente na figura 14.

Figura 13 – Média da variância conforme janelas de análise



Fonte: O Autor, 2023


Tabela 2 – Variância da média de variâncias em amostras

Janela de amostra	Célula MIM( $A^4$ )	Neurônio de rato( $M\Omega^4$ )
2	9.24 E-28	844.05
4	1.56 E-27	1349.09
8	3.96 E-27	369.48
16	1.31 E-26	414.85
32	2.88 E-26	898.84
64	8.16 E-26	1166.84
128	6.48 E-26	157.85
256	2.38 E-25	7.33
516	2.32 E-25	0.73
1024	1.60 E-23	0.01

Fonte: o Autor, 2023.

Em ambas as comparações as curvas de variância de primeira e segunda ordem não demonstram semelhança. Na primeira ordem, a variância dos neurônios de ratos demonstram crescimento variando cada vez menor conforme o aumento da janela analisada enquanto as medidas em células MIM possuem variância crescente em taxas cada vez maiores conforme a aumento da janela de amostragem.

Figura 14 – Variância de segunda ordem dos dados analisados



Fonte: O Autor, 2023

Afim de realizar uma comparação numérica com testes estatísticos dos resultados obtidos foi feita uma comparação de curtose para a variância de segunda ordem entre os sistemas e um teste de correlação cruzada em ambas as ordens de variância. Os resultados do primeiro teste estão dispostos na tabela 3 e do segundo na tabela 4 e figura 15 e 16.

Tabela 3 – Valores de curtose para variância de segunda ordem em mesma série temporal

Neurônios de rato	Células MIM
1.688	8.106

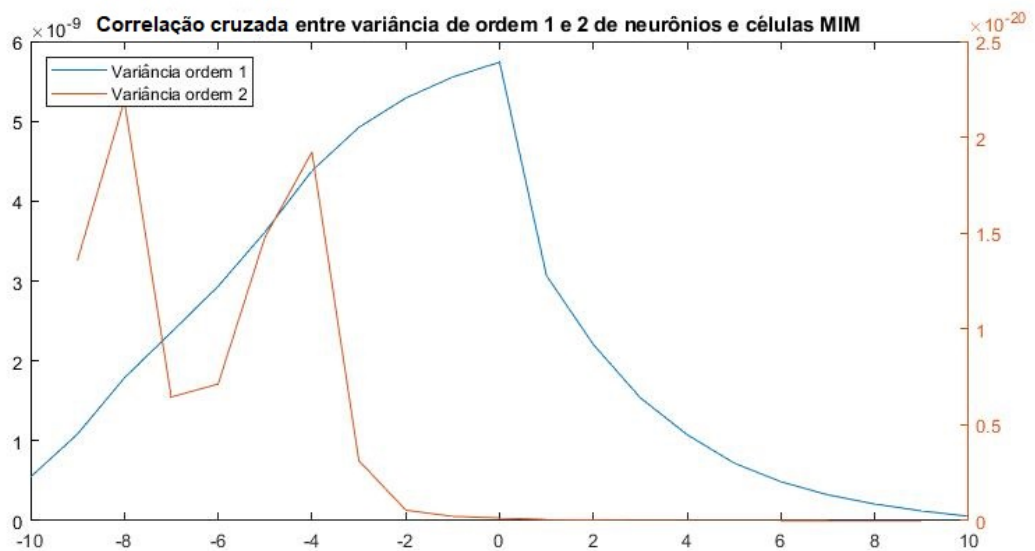
Fonte: o Autor, 2023.

Tabela 4 – Valores de correlação cruzada de variância entre células MIM e neurônios de ratos

Ponto	Variância de ordem 1	Variância de ordem 2
-10	5.47 E-10	
-9	1.08 E-09	1.36E-20
-8	1.79 E-09	2.19E-20
-7	2.36 E-09	6.45E-21
-6	2.93 E-09	7.12E-21
-5	3.61 E-09	1.48E-20
-4	4.38 E-09	1.92E-20
-3	4.92 E-09	3.13E-21
-2	5.29 E-09	5.50E-22
-1	5.55 E-09	2.23E-22
0	5.74 E-09	1.43E-22
1	3.07 E-09	6.25E-23
2	2.20 E-09	2.51E-23
3	1.54 E-09	8.74E-24
4	1.08 E-09	3.38E-24
5	7.21 E-10	1.37E-24
6	4.88 E-10	1.61E-25
7	3.23 E-10	8.02E-27
8	2.09 E-10	7.07E-28
9	1.22 E-10	1.63E-29
10	5.42 E-11	

Fonte: o Autor, 2023.

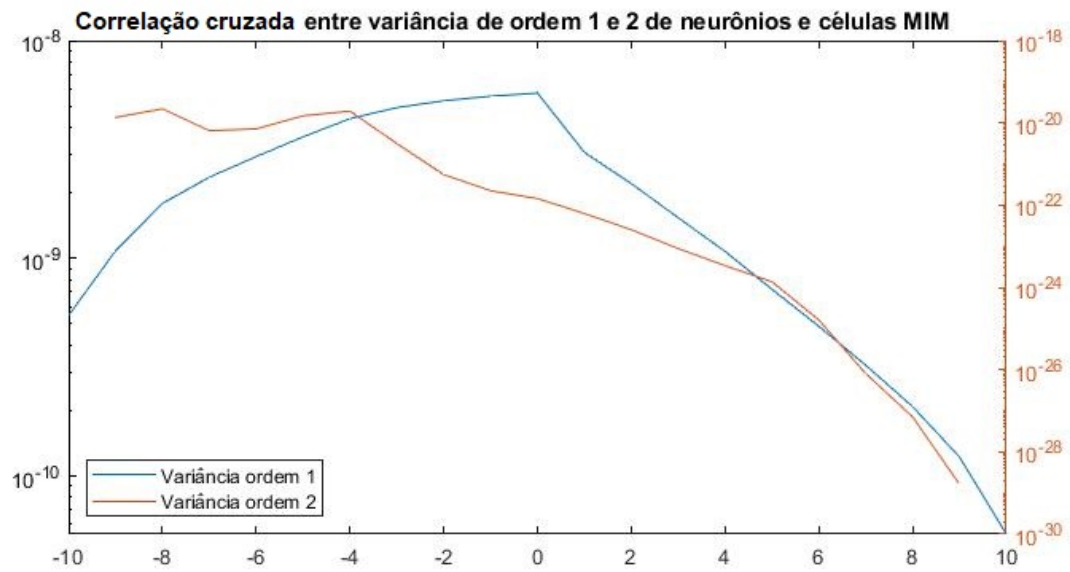
Figura 15 – Correlação cruzada de variância de células MIM e neurônimos



Fonte: O Autor, 2023



Figura 16 – Correlação cruzada de variância em escala logarítmica




Fonte: O Autor, 2023

## 4.2 Variância com estímulos diferentes em série temporal

Foi testada também a abordagem considerando as medidas nos neurônios de ratos como uma única série temporal independente do valor do estímulo. Na base de dados os testes foram feitos em sequência mantendo o mesmo *setup* e alterando o valor da corrente injetada com intervalo de 3 segundos sem estímulo. Desta forma seria possível comparar um maior número de janelas mesmo em estímulos distintos. A resistência em função do tempo nos 5 neurônios foi demonstrada graficamente na figura 17.

Ao comparar as variâncias médias conforme janela analisada nessa circunstância crescendo exponencialmente com base 2 obtém-se os seguintes resultados dispostos na tabela 5. Dispondo os resultados lado-a-lado em suas respectivas escalas obtém-se então o gráfico da figura 18.

Figura 17 – Resistência de neurônios de ratos




Fonte: O Autor, 2023

Tabela 5 – Média da variância em função do tamanho da janela analisada em série temporal única

Janela de amostragem	Célula MIM ( $A^2$ )	Neurônio de Rato ( $M\Omega^2$ )
2	1.66 E-13	55.69
4	2.09 E-13	93.49
8	2.65 E-13	139.63
16	3.54 E-13	166.32
32	5.16 E-13	292.12
64	7.56 E-13	476.35
128	1.16 E-12	633.18
256	1.52 E-12	1364.43
512	2.20 E-12	2447.11
1024	2.89 E-12	4702.05
2048	8.56 E-12	9394.95
4096	1.37 E-11	21202.20
8192	1.62 E-11	29031.30

Fonte: o Autor, 2023.

Figura 18 – Média da variância conforme janelas de análise



Fonte: O Autor, 2023

A variância de segunda ordem também foi calculada da mesma forma que na análise em medidas separadas. Os resultados estão dispostos na tabela 6 e colocados graficamente na figura 19.


Tabela 6 – Variância da média de variâncias em amostras para série temporal única

Janela de amostragem	Célula MIM (A <sup>4</sup> )	Neurônio de Rato (MΩ <sup>4</sup> )
2	9.24 E-28	714.20
4	1.56 E-27	1064.67
8	3.96 E-27	356.09
16	1.31 E-26	7913.04
32	2.88 E-26	169.69 E2
64	8.16 E-26	122.97 E2
128	6.48 E-26	2673.68 E2
256	2.31 E-25	5860.94 E2
512	2.38 E-25	2542.37 E3
1024	1.60 E-23	1101.16 E4
2048	1.32 E-23	6970.55 E4
4096	3.12 E-24	3064.73 E4

Fonte: o Autor, 2023.

Nessa circunstância, em ambas as comparações as curvas de variância de primeira e segunda ordem parecem semelhantes. Na primeira ordem ambas apresentam um formato semelhante a um sigmoide com uma crescente exponencial e um declive no crescimento em janelas maiores. Comportamento também semelhante demonstrado na variância de segunda ordem onde há uma janela de crescimento e posteriormente declive da variância

Figura 19 – Variância de segunda ordem dos dados analisados



Fonte: O Autor, 2023

de segunda ordem após mil pontos na janela em análise para as células MIM e 10 mil para neurônios de ratos.

As mesmas comparações de curtose para a variância de segunda ordem entre os sistemas e o teste de correlação cruzada em ambas as ordens de variância foram aplicadas nesta abordagem. Os resultados do primeiro teste estão dispostos na tabela 7 e do segundo na tabela 8 e figura 20.

Tabela 7 – Valores de curtose para variância de segunda ordem

Neurônios de rato	Células MIM
6.8698	4.2924


Fonte: o Autor, 2023.

Tabela 8 – Valores de correlação cruzada de variância entre células MIM e neurônios de ratos em mesma série temporal

<b>Ponto</b>	<b>Variância de ordem 1</b>	<b>Variância de ordem 2</b>
-11	2.27 E-09	2.24 E-21
-10	4.01 E-09	1.26 E-20
-9	5.56 E-09	2.65 E-20
-8	8.58 E-09	4.68 E-20
-7	1.38 E-08	1.62 E-19
-6	2.02 E-08	3.87 E-19
-5	3.64 E-08	1.27 E-18
-4	6.62 E-08	5.52 E-18
-3	1.25 E-07	1.99 E-17
-2	2.44 E-07	7.71 E-17
-1	5.23 E-07	4.03 E-16
0	8.62 E-07	1.18 E-15
1	6.22 E-07	1.52 E-15
2	3.42 E-07	5.12 E-16
3	1.53 E-07	2.43 E-17
4	1.13 E-07	1.27 E-17
5	7.98 E-08	8.05 E-18
6	5.73 E-08	4.67 E-18
7	3.82 E-08	1.85 E-18
8	2.63 E-08	6.99 E-19
9	1.86 E-08	2.39 E-19
10	1.37 E-08	1.12 E-19
11	9.59 E-09	2.85 E-20

Fonte: o Autor, 2023.

Figura 20 – Correlação cruzada de variância de células MIM e neurônimos



Fonte: O Autor, 2023

## 5 Conclusões

Baseado nos resultados obtidos, este trabalho demonstra que o comportamento das células MIM apresenta um padrão de variação parcialmente semelhante em relação aos neurônios do sistema nervoso central de ratos quando ambos estão submetidos a estímulo elétrico constante. Conforme a literatura previamente sugeria, esse componente se mostra mais instável, proporcionando então níveis de variação que acompanham um padrão onde mesmo janelas de 10000 pontos não demonstram algum nível em que a variância parece atingir estabilidade e assim apresentar pouco crescimento conforme a expansão da janela analisada. Já os neurônios de ratos, diferentemente, tiveram uma variância crescente porém se aproximando da estabilidade pois em janelas superiores a 128 pontos já não havia crescimento da variância superior a 6% de um valor para o próximo em análise da janela e um crescimento de 7,5% desta para a última janela de análise considerando um aumento de 16 vezes no número de elementos considerado para a média. Desta forma ambos apresentam um crescimento constante porém assumindo curvas diferentes como demonstrado pelas variâncias de primeira e segunda ordem nas figuras 13 e 14, onde podemos observar as variâncias de neurônios de ratos se estabilizando e diminuindo sua variância segunda enquanto a das células MIM se mantém crescente em ambas as ordens.

A comparação dos resultados obtidos de células MIM sob tensão constante com os neurônios de ratos em diferentes injeções de corrente na mesma série temporal demonstra um comportamento mais semelhante entre os dois objetos em análise. Ambas apresentam um formato semelhante a um sigmoide tendo o eixo X em escala logarítmica. Desta forma podemos afirmar que mesmo submetendo as amostras usadas no trabalho a estímulos constantes de tensão, temos um padrão de comportamento semelhante a neurônios em diferentes valores de estímulo elétrico. Os testes de correlação cruzada entre as variâncias evidenciam que em ambos os cenários existe correlação cruzada fraca entre as variâncias devido seus baixos valores e formato semelhante apenas a uma curva normal sem outros picos além do ponto 0. Comparando entre cenários, a primeira circunstância com os estímulos constantes, é menos autocorrelata pois em primeira ordem o pico do ponto 0 tem valor 150 vezes menor que o cenário de múltiplos estímulos em mesma série temporal, enquanto na segunda ordem o primeiro cenário não forma uma gaussiana e no segundo obedece uma forma semelhante a primeira ordem. Os testes de curtose também apresentam valores mais próximos na segunda abordagem com um delta de 2,577 comparado a 6,418 na primeira, comprovando uma maior semelhança na distribuição dos dados em relação a média.

Considerando as circunstâncias contempladas no estudo, é possível afirmar que há um padrão semelhante apenas na circunstância específica onde consideramos um neurônio

biológico submetido a uma situação que não acontece naturalmente no cérebro que é os múltiplos níveis de estímulo elétrico. Os neurônios animais se comportam no geral com menos variação entre janelas de média a longa exposição, enquanto as medidas selecionadas, mesmo se mantendo no mesmo estado de resistência, apresentam uma variabilidade ainda crescente e distantes da estabilidade da possível variação do comportamento resistivo

## 5.1 Trabalhos futuros

Aumentar base de medidas do LCE considerando outras amostras de diferentes fabricantes, processos e outros materiais para verificar a estabilidade em diferentes circunstâncias. Possivelmente também outros processos de SET de estado para observar os possíveis impactos na estabilidade da resistência da amostra medida.

Comparar com outras bases que mostrem o comportamento elétrico de neurônios do sistema nervoso central. Outras bases de dados disponíveis na internet publicamente ou mediante acesso privado para comparar outras circunstâncias de teste em neurônios biológicos. Ou sugerir testes para pesquisas neurológicas em que ocorra situações mais semelhantes aos processos de aquisição de dados usados no LCE para a caracterização elétrica de neurônios como submeter a amostra à tensão contínua. Idealmente essas bases teriam um número maior de pontos em cada medida para aproveitarmos o potencial da base de dados já coletada.

Estudar os impactos das diferenças destacadas neste trabalho em sistemas de hardware construídos com ReRam. Averiguar a possibilidade de construir um sistema completo de rede neural resistiva utilizando células MIM. Analisar como melhorar o desempenho de estrutura de processamento construída com esta técnica e estes materiais.

## 5.2 Contribuição científica

Este trabalho fez parte do projeto de pesquisa Sinapses Eletrônicas para Computação Neuromórfica Chamada CNPq/MCTI/SEMPI N<sup>o</sup> 14/2021.



## Referências Bibliográficas

- ALSHAREF, A.; JAIN, P.; ARORA, M.; ZAHRA, S. R.; GUPTA, G. *et al.* Cache memory: an analysis on performance issues. In: IEEE. *2021 8th International Conference on Computing for Sustainable Global Development (INDIACom)*. [S.l.], 2021. p. 184–188.
- ARIKPO, I.; OGBAN, F.; ETENG, I. Von neumann architecture and modern computers. *Global Journal of Mathematical Sciences*, v. 6, n. 2, p. 97–103, 2007.
- CHAKRABORTY, I.; ALI, M.; ANKIT, A.; JAIN, S.; ROY, S.; SRIDHARAN, S.; AGRAWAL, A.; RAGHUNATHAN, A.; ROY, K. Resistive crossbars as approximate hardware building blocks for machine learning: Opportunities and challenges. *Proceedings of the IEEE*, IEEE, v. 108, n. 12, p. 2276–2310, 2020.
- CHEN, C.; GOUX, L.; FANTINI, A.; CLIMA, S.; DEGRAEVE, R.; REDOLFI, A.; CHEN, Y. Y.; GROESENEKEN, G.; JURCZAK, M. Endurance degradation mechanisms in tin\ta2o5\ta resistive random-access memory cells. *Applied Physics Letters*, AIP Publishing LLC, v. 106, n. 5, p. 053501, 2015.
- EIGENMANN, R.; LILJA, D. J. Von neumann computers. *Wiley Encyclopedia of Electrical and Electronics Engineering*, Wiley, v. 23, p. 387–400, 1998.
- FLEETWOOD, D. M. 'border traps' in mos devices. *IEEE transactions on nuclear science*, IEEE, v. 39, n. 2, p. 269–271, 1992.
- HILLE, B. Ion channels of excitable membranes. In: *3rd ed. Sunderland Mass.* [S.l.]: Sinauer, 2001.
- HODGKIN, A. L.; HUXLEY, A. F. A quantitative description of membrane current and its application to conduction and excitation in nerve. *The Journal of physiology*, Wiley-Blackwell, v. 117, n. 4, p. 500, 1952.
- IELMINI, D.; WASER, R. *Resistive switching: from fundamentals of nanoionic redox processes to memristive device applications*. [S.l.]: John Wiley & Sons, 2015.
- KANDEL, E. R.; SCHWARTZ, J. H.; JESSELL, T. M.; SIEGELBAUM, S. A.; HUDSPETH, A. Principles of neural science, fifth editon. In: *Principles of Neural Science*. [S.l.]: McGraw-Hill Education, 2013.
- KIRTON, M.; UREN, M. Noise in solid-state microstructures: A new perspective on individual defects, interface states and low-frequency (1/f) noise. *Advances in Physics*, Taylor & Francis, v. 38, n. 4, p. 367–468, 1989.
- LANZA, M.; WONG, H.-S. P.; POP, E.; IELMINI, D.; STRUKOV, D.; REGAN, B. C.; LARCHER, L.; VILLENA, M. A.; YANG, J. J.; GOUX, L. *et al.* Recommended methods to study resistive switching devices. *Advanced Electronic Materials*, Wiley Online Library, v. 5, n. 1, p. 1800143, 2019.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *nature*, Nature Publishing Group UK London, v. 521, n. 7553, p. 436–444, 2015.

- MOULSON, A. Transition metal oxides. In: *Concise Encyclopedia of Advanced Ceramic Materials*. [S.l.]: Elsevier, 1991. p. 497–499.
- OHNO, S.; TOPRASERTPONG, K.; TAKAGI, S.; TAKENAKA, M. Si microring resonator crossbar arrays for deep learning accelerator. *Japanese Journal of Applied Physics*, IOP Publishing, v. 59, n. SG, p. SGGE04, feb 2020. Disponível em: <<https://dx.doi.org/10.35848/1347-4065/ab6d82>>.
- OVIEDO, H.; REYES, A. D. Boosting of neuronal firing evoked with asynchronous and synchronous inputs to the dendrite. *Nature neuroscience*, Nature Publishing Group US New York, v. 5, n. 3, p. 261–266, 2002. Disponível em: <<http://www.neuralsignal.org>>.
- PUGLISI, F. M.; PADOVANI, A.; LARCHER, L.; PAVAN, P. Random telegraph noise: Measurement, data analysis, and interpretation. In: IEEE. *2017 IEEE 24th International Symposium on the Physical and Failure Analysis of Integrated Circuits (IPFA)*. [S.l.], 2017. p. 1–9.
- SAKAMOTO, T.; SUNAMURA, H.; KAWAURA, H.; HASEGAWA, T.; NAKAYAMA, T.; AONO, M. Nanometer-scale switches using copper sulfide. *Applied Physics Letters*, American Institute of Physics, v. 82, n. 18, p. 3032–3034, 2003.
- SHI, Y.; LIANG, X.; YUAN, B.; CHEN, V.; LI, H.; HUI, F.; YU, Z.; YUAN, F.; POP, E.; WONG, H.-S. P. *et al.* Electronic synapses made of layered two-dimensional materials. *Nature Electronics*, Nature Publishing Group, v. 1, n. 8, p. 458–465, 2018.
- SILVER, D.; SCHRITTWIESER, J.; SIMONYAN, K.; ANTONOGLU, I.; HUANG, A.; GUEZ, A.; HUBERT, T.; BAKER, L.; LAI, M.; BOLTON, A. *et al.* Mastering the game of go without human knowledge. *nature*, Nature Publishing Group, v. 550, n. 7676, p. 354–359, 2017.
- SIMOEN, E.; CLAEYS, C. *Random telegraph signals in semiconductor devices*. [S.l.]: IOP publishing, 2016.
- SMITH, A. J. Cache memories. *ACM Computing Surveys (CSUR)*, ACM New York, NY, USA, v. 14, n. 3, p. 473–530, 1982.
- VALOV, I.; WASER, R.; JAMESON, J. R.; KOZICKI, M. N. Electrochemical metallization memories—fundamentals, applications, prospects. *Nanotechnology*, IOP Publishing, v. 22, n. 25, p. 254003, 2011.
- WEDIG, A.; LUEBBEN, M.; CHO, D.-Y.; MOORS, M.; SKAJA, K.; RANA, V.; HASEGAWA, T.; ADEPALLI, K. K.; YILDIZ, B.; WASER, R. *et al.* Nanoscale cation motion in taox, hfox and tiox memristive systems. *Nature nanotechnology*, Nature Publishing Group, v. 11, n. 1, p. 67–74, 2016.
- WONG, H.-S. P.; LEE, H.-Y.; YU, S.; CHEN, Y.-S.; WU, Y.; CHEN, P.-S.; LEE, B.; CHEN, F. T.; TSAI, M.-J. Metal–oxide rram. *Proceedings of the IEEE*, IEEE, v. 100, n. 6, p. 1951–1970, 2012.
- WULF, W. A.; MCKEE, S. A. Hitting the memory wall: Implications of the obvious. *ACM SIGARCH computer architecture news*, ACM New York, NY, USA, v. 23, n. 1, p. 20–24, 1995.

XIA, Q.; YANG, J. J. Memristive crossbar arrays for brain-inspired computing. *Nature materials*, Nature Publishing Group UK London, v. 18, n. 4, p. 309–323, 2019.

XU, X.; DING, Y.; HU, S. X.; NIEMIER, M.; CONG, J.; HU, Y.; SHI, Y. Scaling for edge inference of deep neural networks. *Nature Electronics*, Nature Publishing Group, v. 1, n. 4, p. 216–222, 2018.