

Universidade Federal de Santa Catarina
Campus Reitor João David Ferreira Lima
Departamento de Engenharia Elétrica e Eletrônica



Felipe Hugo Costa de Oliveira

Neurônios LIF Analógicos para Implementação de Redes
Neurais Pulsadas

Florianópolis

2023

Felipe Hugo Costa de Oliveira

**Neurônios LIF Analógicos para Implementação de
Redes Neurais Pulsadas**

Trabalho de Conclusão de Curso apresentado à Universidade Federal de Santa Catarina como parte dos requisitos necessários para a obtenção do título de Bacharel em Engenharia Eletrônica.
Orientador: Prof. Dr. Cesar Ramos Rodrigues

Universidade Federal de Santa Catarina
Campus Reitor João David Ferreira Lima
Departamento de Engenharia Elétrica e Eletrônica

Florianópolis
2023

Ficha catalográfica gerada por meio de sistema automatizado gerenciado pela BU/UFSC.
Dados inseridos pelo próprio autor.

Oliveira, Felipe Hugo Costa
Neurônios LIF Analógicos para Implementação de Redes
Neurais Pulsadas / Felipe Hugo Costa Oliveira ;
orientador, Cesar Ramos Rodrigues, 2024.
60 p.

Trabalho de Conclusão de Curso (graduação) -
Universidade Federal de Santa Catarina, Centro Tecnológico,
Graduação em Engenharia Eletrônica, Florianópolis, 2024.

Inclui referências.

1. Engenharia Eletrônica. 2. Redes Neurais Pulsadas. 3.
Redes Neurais Artificiais. 4. Modelo Integração, Disparo
com Vazamento. 5. Hardware. I. Rodrigues, Cesar Ramos. II.
Universidade Federal de Santa Catarina. Graduação em
Engenharia Eletrônica. III. Título.

Felipe Hugo Costa de Oliveira

Neurônios LIF Analógicos para Implementação de Redes Neurais Pulsadas

Este Trabalho de Conclusão de Curso foi julgado adequado para obtenção do Título de “Bacharel em Engenharia Eletrônica” e aprovado em sua forma final pelo Curso de Graduação em Engenharia Eletrônica.

Florianópolis, 28 de fevereiro de 2024



Documento assinado digitalmente

Daniela Ota Hisayasu Suzuki

Data: 28/02/2024 15:59:25-0300

CPF: ***.397.389-**

Verifique as assinaturas em <https://v.ufsc.br>

Profa. Dra. Daniela Ota Hisayasu Suzuki,
Coordenadora do Curso

Banca Examinadora:



Documento assinado digitalmente

Cesar Ramos Rodrigues

Data: 28/02/2024 14:57:48-0300

CPF: ***.557.990-**

Verifique as assinaturas em <https://v.ufsc.br>

Prof. Dr. Cesar Ramos Rodrigues
Universidade Federal de Santa Catarina
Orientador



Documento assinado digitalmente

Marcio Cherem Schneider

Data: 28/02/2024 15:26:43-0300

CPF: ***.556.799-**

Verifique as assinaturas em <https://v.ufsc.br>

Prof. Dr. Márcio Cherem Schneider
Universidade Federal de Santa Catarina

Gabriel Maranhão Soares

Me. Gabriel Maranhão Soares
Universidade Federal de Santa Catarina

Agradecimentos

Gostaria de agradecer primeiramente a Deus pela oportunidade de estudar e conhecer pessoas incríveis. Gostaria de agradecer a minha família por todo o apoio e suporte nesses anos de graduação, em especial para minha mãe Joelma e minha avó Jovita. Muito obrigado por tudo. Gostaria de agradecer aos professores que fizeram parte dessa jornada, muito obrigado por todo o conhecimento compartilhado. Agradecimento especial para meu orientador, Cesar, por todo suporte nesse último ano. Agradecimento aos meus amigos da graduação, por toda ajuda nesses longos anos. Em especial para o Pedro Paulo, Tatianne, Alexandre e Simas. E um agradecimento especial para meus amigos do laboratório de circuitos integrados, em especial para o Deni e o Gabriel. Muito obrigado por todo conhecimento compartilhado, meus amigos e todos os bons momentos no C1.

Resumo

NENGO é uma biblioteca implementada em Python que permite criar redes neurais com base nos modelos matemáticos dos neurônios biológicos. Os neurônios simulados nela podem ser considerados biologicamente plausíveis devido à sua saída em pulsos, assim como os neurônios biológicos. Devido a essa característica, ela tem sido muito utilizada para o processamento de sinais biomédicos, como o processamento de sinais sensoriais de tato, por exemplo. No entanto, uma barreira para essas redes é a necessidade de um microcontrolador para operar, o que torna inviável muitas aplicações em que o consumo ultra baixo de energia é mandatório. Este trabalho tem como objetivo desenvolver um neurônio capaz de emular o comportamento dos neurônios implementados no 'NENGO' visando baixo consumo de potência e área reduzida em layout. Essa abordagem visa viabilizar a transição das redes simuladas em software para um ambiente de hardware dedicado, proporcionando uma resposta análoga àquela obtida nos neurônios do simulados no 'NENGO'.

Palavras-Chave: 1. Redes Neurais Artificiais 2. Redes Neurais Pulsadas 3. Hardware 4. Modelo Integração, disparo com vazamento

Abstract

NENGO is a library implemented in Python that allows the creation of neural networks based on mathematical models of biological neurons. The simulated neurons in it can be considered biologically plausible due to their output in pulses, similar to biological neurons. Because of this characteristic, it has been widely used for processing biomedical signals, such as the processing of tactile sensory signals, for example. However, a barrier for these networks is the need for a microcontroller to operate, making it impractical for many applications where ultra-low power consumption is mandatory. This work aims to design a neuron that responds in the same way as the neurons implemented in 'NENGO', thereby enabling the implementation of simulated networks in software on dedicated hardware.

Keywords: 1.Artificial Neural Network 2.Spike Neural Network 3. Hardware 4. Leaky Integrate-and-Fire

Lista de figuras

Figura 1 – Esquemático do sistema biomimético para a reprodução dos sentidos de tato utilizando próteses	14
Figura 2 – <i>Curvas características (intercepts) da taxa de disparo de diferentes neurônios como função da diferença de potencial, em volt.</i>	15
Figura 3 – Curva I_D VS V_{GS}	18
Figura 4 – Modelo ac do transistor MOSFET em baixas frequências	19
Figura 5 – Representação de um neurônio	20
Figura 6 – Representação de um canal iônico	23
Figura 7 – Fases do potencial de ação	23
Figura 8 – Circuito equivalente do modelo LIF para neurônios	26
Figura 9 – Comportamento da tensão de membrana para uma corrente constante	27
Figura 10 – Esquemático simplificado do modelo LIF	28
Figura 11 – Comportamento do modelo LIF ao longo do tempo para uma entrada I_{in} de corrente	29
Figura 12 – Esquemático do neurônio	30
Figura 13 – Sinais de entrada e saída do comparador Schmitt Trigger	32
Figura 14 – Esquemático do circuito auxiliar para geração de <i>intercepts</i> positivos	34
Figura 15 – Esquemático do circuito auxiliar para geração dos <i>intercepts</i> negativos	35
Figura 16 – Resposta dos circuitos não lineares	36
Figura 17 – <i>Intercepts</i> positivos, com intervalos de frequência de 8 à 15 Hz, 16 à 40 Hz e 26 à 40 Hz	38
Figura 18 – <i>Intercepts</i> positivos, com intervalos de frequência de 60 Hz á 90 Hz e 90 à 127 Hz	38
Figura 19 – <i>Intercepts</i> positivos, com intervalos de frequência de 165 Hz á 230 Hz e 300 à 408 Hz	39
Figura 20 – Tensão da membrana, V_m , para os <i>Intercepts</i> positivos, com intervalos de frequência de 8 à 15 Hz, 16 à 40 Hz e 26 à 40 Hz	40
Figura 21 – Tensão da membrana, V_m , para os <i>Intercepts</i> positivos, com intervalos de frequência de 60 Hz á 90 Hz e 90 à 127 Hz	40
Figura 22 – Tensão da membrana, V_m , para os <i>Intercepts</i> positivos, com intervalos de frequência de 165 Hz á 230 Hz e 300 à 408 Hz	41

Figura 23 – Disparos na saída, V_{out} , para os <i>Intercepts</i> positivos, com intervalos de frequência de 8 à 15 Hz, 16 à 40 Hz e 26 à 40 Hz	42
Figura 24 – Disparos na saída, V_{out} , para os <i>Intercepts</i> positivos, com intervalos de frequência de 60 Hz á 90 Hz e 90 à 127 Hz	42
Figura 25 – Disparos na saída, V_{out} , para os <i>Intercepts</i> positivos, com intervalos de frequência de 165 Hz á 230 Hz e 300 à 408 Hz	43
Figura 26 – Disparos na saída, V_{out} , para os <i>Intercepts</i> negativos, com intervalos de frequência de 10 à 20 Hz, 16 á 30 Hz e 26 à 45 Hz	44
Figura 27 – Disparos na saída, V_{out} , para os <i>Intercepts</i> negativos, com intervalos de frequência de 54 á 88 Hz e 82 à 127 Hz	44
Figura 28 – Disparos na saída, V_{out} , para os <i>Intercepts</i> negativos, com intervalos de frequência de 155 á 231 Hz e 290 à 414 Hz	45
Figura 29 – Tensão da membrana, V_m , para os <i>Intercepts</i> negativos, com intervalos de frequência de 10 Hz á 20 Hz, 16 à 30 Hz e 26 à 45 Hz	46
Figura 30 – Tensão da membrana, V_m , para os <i>Intercepts</i> negativos, com intervalos de frequência de 54 à 88 Hz e 82 à 127 Hz	46
Figura 31 – Tensão da membrana, V_m , para os <i>Intercepts</i> negativos, com intervalos de frequência de 155 à 231 Hz e 290 à 414 Hz	47
Figura 32 – Disparos na saída, V_{out} , para os <i>Intercepts</i> negativos, com intervalos de frequência de 10 Hz á 20 Hz, 16 à 30 Hz e 26 à 45 Hz	48
Figura 33 – Disparos na saída, V_{out} , para os <i>Intercepts</i> negativos, com intervalos de frequência de 54 à 88 Hz e 82 à 127 Hz	48
Figura 34 – Disparos na saída, V_{out} , para os <i>Intercepts</i> negativos, com intervalos de frequência de 155 à 231 Hz e 290 à 414 Hz	49
Figura 35 – Leiaute do neurônio com seu respectivo circuito auxiliar	55
Figura 36 – Resultado das simulações dos <i>Intercepts</i> com a vista nível esquemático e extraída pós leiaute 1	55
Figura 37 – Resultado das simulações dos <i>Intercepts</i> com a vista nível esquemático e extraída pós leiaute 2	56

Lista de tabelas

Tabela 1	–	Dimensões dos transistores do neurônio	33
Tabela 2	–	Dimensões dos transistores do circuito para geração dos <i>intercepts</i> positivos	34
Tabela 3	–	Dimensões dos transistores do circuito para geração de <i>intercepts</i> negativos	35
Tabela 4	–	Variação da frequência de disparo do neurônio com <i>intercepts</i> positivos em relação à variação de temperatura para uma taxa de disparo baixa	50
Tabela 5	–	Variação da frequência de disparo do neurônio com <i>intercepts</i> positivos em relação à variação de temperatura para uma taxa de disparo baixa	50
Tabela 6	–	Variação da frequência de disparo do neurônio com <i>intercepts</i> positivos em relação à variação de temperatura para uma taxa de disparo alta	50
Tabela 7	–	Variação da frequência de disparo do neurônio com <i>intercepts</i> positivos em relação à variação de temperatura para uma taxa de disparo alta	50
Tabela 8	–	Variação da frequência de disparo do neurônio com <i>intercepts</i> negativos em relação à variação de temperatura para uma taxa de disparo baixa	51
Tabela 9	–	Variação da frequência de disparo do neurônio com <i>intercepts</i> negativos em relação à variação de temperatura para uma taxa de disparo baixa	51
Tabela 10	–	Variação da frequência de disparo do neurônio com <i>intercepts</i> negativos em relação à variação de temperatura para uma taxa de disparo alta	51
Tabela 11	–	Variação da frequência de disparo do neurônio com <i>intercepts</i> negativos em relação à variação de temperatura para uma taxa de disparo alta	51
Tabela 12	–	Variação da frequência de disparo do neurônio com <i>intercepts</i> positivos em relação à variação de processos para uma taxa de disparo baixa	52

Tabela 13 – Variação da frequência de disparo do neurônio com <i>intercepts</i> positivos em relação à variação de processos para uma taxa de disparo baixa	52
Tabela 14 – Variação da frequência de disparo do neurônio com <i>intercepts</i> positivos em relação à variação de processos para uma taxa de disparo alta	53
Tabela 15 – Variação da frequência de disparo do neurônio com <i>intercepts</i> positivos em relação à variação de processos para uma taxa de disparo alta	53
Tabela 16 – Variação da frequência de disparo do neurônio com <i>intercepts</i> negativos em relação à variação de processos para uma taxa de disparo baixa	53
Tabela 17 – Variação da frequência de disparo do neurônio com <i>intercepts</i> negativos em relação à variação de processos para uma taxa de disparo baixa	53
Tabela 18 – Variação da frequência de disparo do neurônio com <i>intercepts</i> negativos em relação à variação de processos para uma taxa de disparo alta	54
Tabela 19 – Variação da frequência de disparo do neurônio com <i>intercepts</i> negativos em relação à variação de processos para uma taxa de disparo alta	54
Tabela 20 – Erros absoluto e relativo entre a vista nível esquemático e extraída pós leiaute com relação as curvas da figura 36.	56
Tabela 21 – Erros absoluto e relativo entre a vista nível esquemático e extraída pós leiaute com relação as curvas da figura 36.	56
Tabela 22 – Erros absoluto e relativo entre a vista nível esquemático e extraída pós leiaute com relação as curvas da figura 37.	57
Tabela 23 – Erros absoluto e relativo entre a vista nível esquemático e extraída pós leiaute com relação as curvas da figura 37.	57

Lista de Siglas e Abreviaturas

RNP	<i>Redes Neurais pulsadas</i>
RNA	<i>Redes Neurais Artificiais</i>
LIF	<i>Leaky Integrate-and-Fire</i>
CMOS	<i>Complementary metal-oxide-semiconductor</i>
TSMC	<i>Taiwan Semiconductor Manufacturing Company</i>
SNN	<i>Spike Neural Network</i>

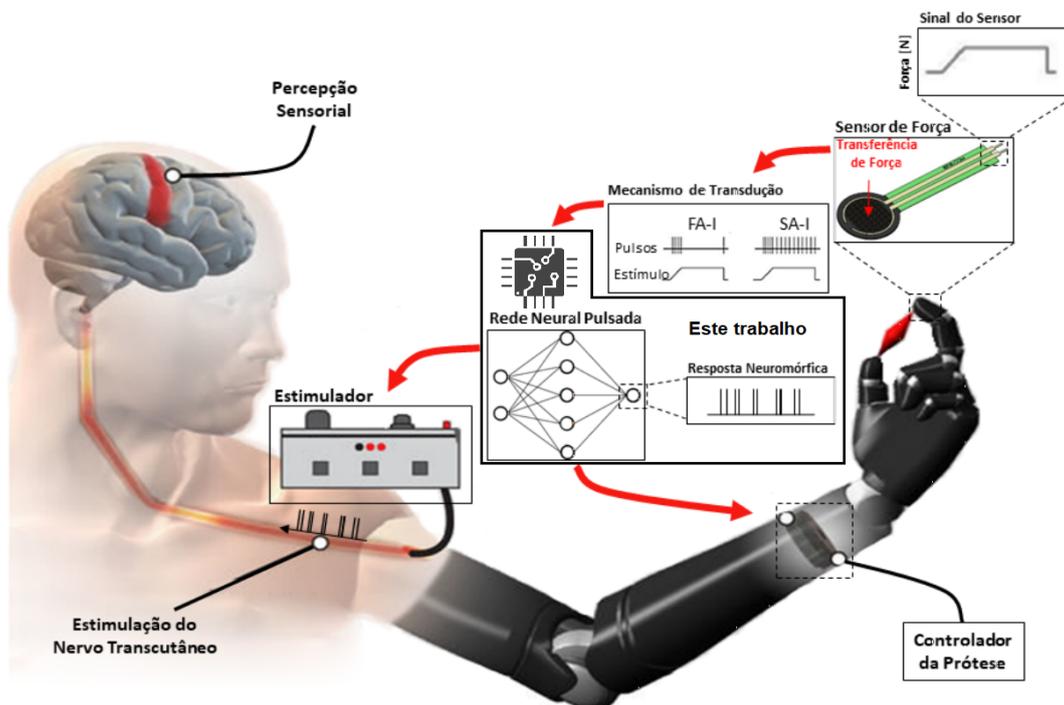
Sumário

1	INTRODUÇÃO	14
2	REVISÃO TEÓRICA	17
2.1	Relação não linear do CMOS: V_{GS} por I_D	17
2.2	Transcondutâncias do dispositivo	18
2.3	Neurônios biológicos e sua dinâmica de funcionamento	20
2.3.1	Canais e fluxo de íons através da membrana	20
2.3.2	O potencial de ação	21
2.4	Modelo matemático do neurônio Integração e Disparo com Vazamento	24
2.5	Modelo LIF em circuito integrado	26
3	PROJETO	30
3.1	Neurônio	30
3.2	Circuito auxiliar	33
4	RESULTADOS	37
4.1	<i>Intercepts</i> e frequência de disparo	37
4.2	Variação de temperatura e processo	49
4.2.1	Temperatura	49
4.2.2	Variação de processos	51
4.2.3	Consumo de potência e energia por disparo	54
4.2.4	Leiaute	54
5	CONCLUSÃO	58
	REFERÊNCIAS BIBLIOGRÁFICAS	60

1 Introdução

Ao longo do último século diversos pesquisadores, como Alan Hodgkin and Andrew Huxley, vêm desenvolvendo modelos matemáticos que descrevem o potencial de ação dos neurônios. Por conta do potencial de ação, seres humanos podem, por exemplo, sentir toque e identificar pequenas irregularidades ao deslizar os dedos em superfícies (KANDEL JAMES H. SCHWARTZ,). Quando uma pessoa perde um membro, ela perde parte do circuito que transmitia a informação para o cérebro. Porém a outra parte do circuito permanece inalterada por um determinado período. Diversos pesquisadores estudam formas de fazer com que pessoas que perderam algum membro possam voltar a sentir. A figura 1 mostra um sistema em que um ser humano, utilizando uma prótese, recebe estímulos que foram gerados por uma rede neural pulsada, ou *Spike Neural Network*, e que são passados para o cérebro por meio de um estimulador.

Figura 1 – Esquemático do sistema biomimético para a reprodução dos sentidos de tato utilizando próteses



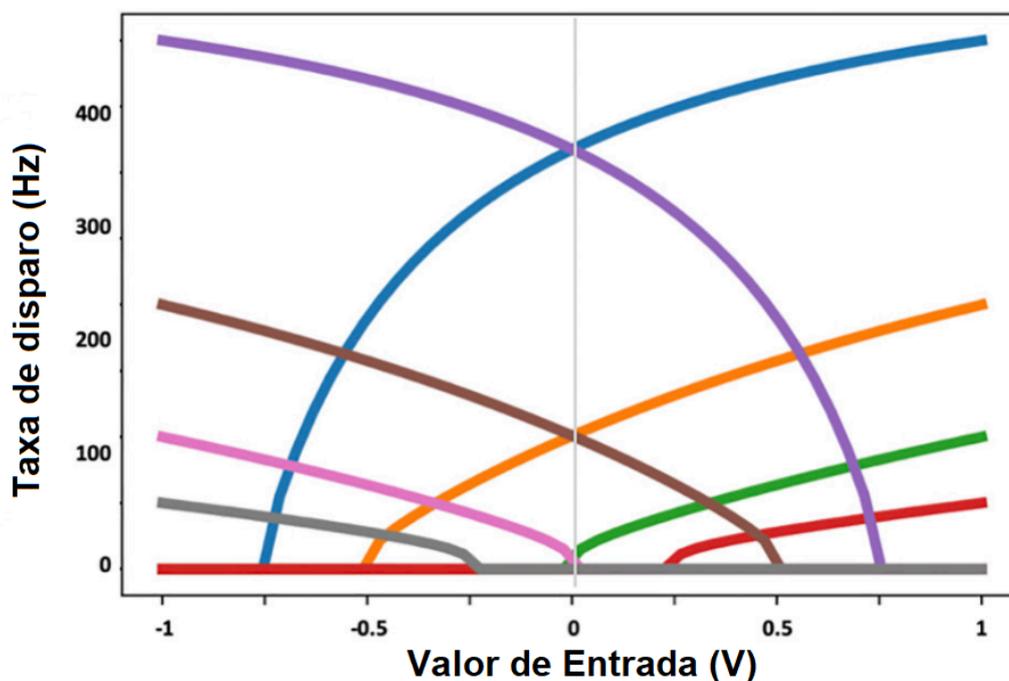
Fonte: Adaptado de (JONE, 2023).

A proposta deste trabalho é o projeto de uma biblioteca com neurônios analógicos

para a implementação de redes neurais pulsadas, similares às simuladas pela plataforma NENGO.

O objetivo final da investigação que abarca este trabalho é o projeto de blocos de circuitos neuromórficos e sua aplicação no sensoriamento tátil e controle de próteses de mão. Existem softwares, como o NENGO (NENGO, 2023) e hardwares, como Loihi (INTEL, 2023) que implementam SNN que transmitem pulsos e simulam o potencial de ação. A biblioteca NENGO, por exemplo, permite a simulação de variados modelos de neurônios, desde os mais simples como o modelo de integração-disparo e vazamento ou *Leaky integrate-and-fire*, LIF, até os mais complexos como o Hodgkin–Huxley. Uma das principais características dos neurônios simulados no NENGO são as curvas de *intercepts*. As curvas ilustram que cada neurônio apresenta uma resposta única em termos de frequência de disparo, dependendo da diferença de potencial de entrada correspondente. Para um valor de entrada constante, diferentes neurônios apresentam distintas frequências de operação. A figura 2 mostra as curvas de *intercepts*.

Figura 2 – Curvas características (*intercepts*) da taxa de disparo de diferentes neurônios como função da diferença de potencial, em volt.



Fonte: Adaptado de (HAZAN; TSUR, 2021).

Quando um toque ou escorregamento é sentido por uma prótese e identificado por meio de uma SNN, é possível fechar o primeiro elo, conforme mostrado na figura 1. É

possível enviar uma resposta à prótese para que esta segure mais firmemente um objeto escorregando ou emita algum sinal para o usuário quando ocorrer algum toque. Já existem trabalhos que conseguem identificar toque e escorregamento, utilizando as SNN implementadas no NENGO (JONE, 2023). Mas a barreira para se usar redes feitas em softwares em aplicações em próteses, por exemplo, é o fator computacional. É necessário um computador para implementá-las e computadores precisam de espaço e apresentam consumo de potência acima de 10W (RASPBERRY, 2023). Partindo desse problema, este trabalho propõe uma implementação de neurônios do modelo LIF que reproduzam o comportamento dos neurônios simulados em software. Ao obter um neurônio com comportamento semelhante ao simulado em software, torna-se factível a transição dessa rede neural para hardware.

2 Revisão Teórica

A resposta não linear do transistor MOSFET foi essencial para a aproximação da resposta do neurônio aos *intercepts* mostrados anteriormente. Este comportamento será abordado na primeira parte do capítulo. Na segunda parte do capítulo será abordado o potencial de ação. Por fim será discutida a modelagem matemática do neurônio e sua implementação em circuito eletrônico.

2.1 Relação não linear do CMOS: V_{GS} por I_D

O transistor MOSFET é um dispositivo que apresenta uma relação não linear entre a tensão porta-fonte (V_{GS}) e a corrente de dreno (I_D) quando está em saturação e em inversão fraca. A inversão fraca é caracterizada por um aumento da tensão de porta, fazendo com que a curvatura da banda aumente e isso implica em um aumento no potencial de superfície. No caso em que a curvatura é grande o suficiente para posicionar a borda da banda de condução na interface $S_i-S_iO_2$ abaixo do nível intrínseco por uma quantidade de potencial ϕ_f , isso indicará que, para essa região, a condutividade foi invertida de tipo p, lacunas, para tipo n, elétrons pelo campo aplicado. Esta região invertida é conhecida como canal, cuja condutividade é controlada pela porta do dispositivo. Essa propriedade de um capacitor MOS que forma a base de ação do transistor MOS. Para faixa de curvatura da banda entre ϕ_f e $2\phi_f$, o canal é intitulado como fracamente invertido e para curvatura maior que $2\phi_f$, é designado como fortemente invertido (BHATTACHARYYA, 2009). Utilizando o modelo ACM (SCHNEIDER, 2010), a condição para o transistor estar em inversão fraca é apresentar nível de inversão $i_f < 1$ e $V_{DS} > 4\phi_t$, onde ϕ_t é a tensão térmica. A equação 2.1 mostra a relação exponencial aproximada entre a corrente de dreno e as tensões V_G e V_S , considerando o fator de inclinação $n = 1$ (SCHNEIDER, 2010).

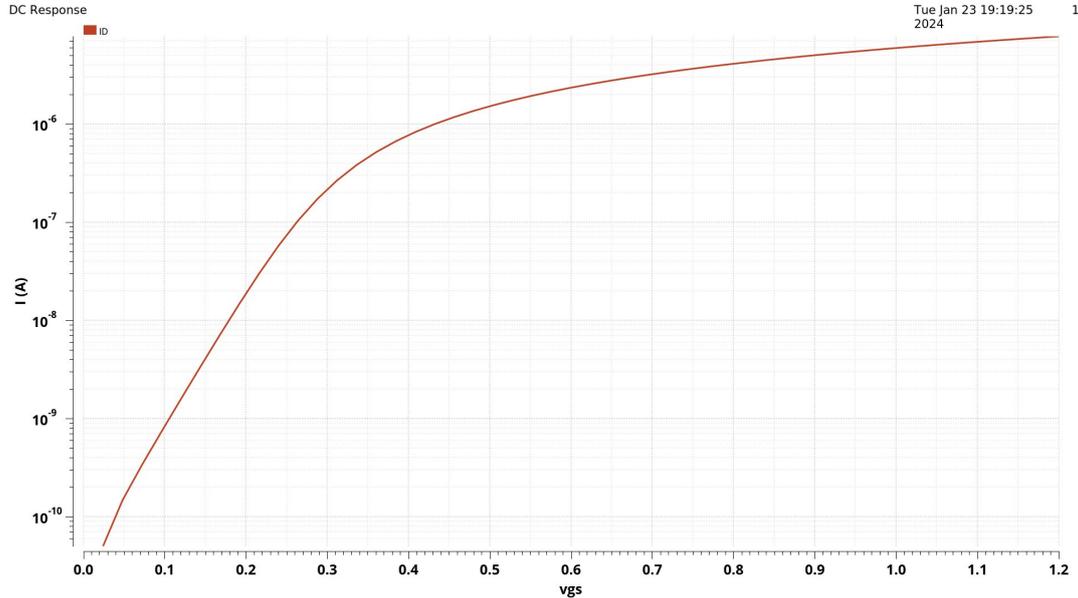
$$I_D \cong I_0 e^{\frac{V_G - VT_0}{n\phi_t}} \left(e^{-\frac{V_S}{\phi_t}} \right) \quad (2.1)$$

onde $I_0 = u_n C'_{ox} n \frac{W}{L} \phi_t^2$, u_n é a mobilidade dos elétrons, C'_{ox} é a capacitância do óxido por unidade de área, W é a largura do canal, L é o comprimento do canal.

Ligando o dispositivo como diodo, isto é, curto circuitando os terminais de porta e dreno, podemos garantir que o dispositivo irá operar em saturação, desde que $V_{DS} > 4\phi_t$. A Figura 3 mostra a variação de ID-VGS. Com o transistor operando em inversão

fraca, além do menor consumo de corrente, característica da inversão fraca, a relação exponencial de V_{GS} x I_D , mostrada na figura 2, será utilizada para a implementação das respostas não-lineares dos neurônios, caracterizadas pelas curvas de *intercepts*.

Figura 3 – Curva I_D VS V_{GS}



Fonte: Autor

Através dessa relação exponencial, o neurônio proposto neste trabalho é capaz de reproduzir as curvas características da taxa de disparo ou *intercepts*, as quais variam de acordo com a diferença de potencial aplicada, conforme ilustrado anteriormente na figura 2. Isso é possível variando a corrente que passa pelo transistor ligado como diodo. A variação da corrente de dreno resulta em uma tensão logarítmica V_{GS} semelhante àquelas observadas no Nengo. Essa tensão é então aplicada ao substrato do transistor da entrada do neurônio, que por sua vez gera a corrente de entrada do circuito.

2.2 Transcondutâncias do dispositivo

No transistor MOSFET, existem 4 transcondutâncias, sendo elas g_{ms} , g_{mg} , g_{md} e g_{mb} . Elas são definidas como a variação da corrente de dreno em função das variações de tensão em cada um dos terminais.

$$\Delta I_D \cong g_{mg} \cdot \Delta V_G - g_{ms} \cdot \Delta V_S + g_{md} \cdot \Delta V_D + g_{mb} \cdot \Delta V_B \quad (2.2)$$

onde

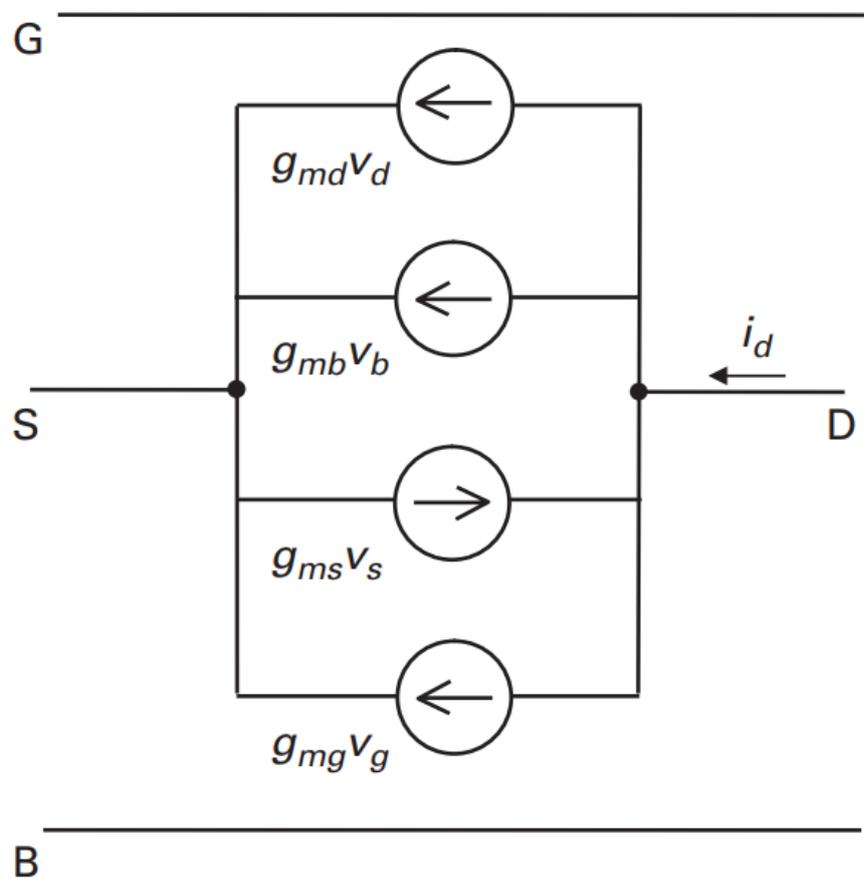
$$g_{mg} = \frac{\partial I_D}{\partial V_G}, g_{ms} = -\frac{\partial I_D}{\partial V_S}, g_{md} = \frac{\partial I_D}{\partial V_D}, g_{mb} = \frac{\partial I_D}{\partial V_B} \quad (2.3)$$

Considerando uma variação igual nas tensões aplicadas na porta, fonte, dreno e substrato, temos $\Delta I_D = 0$ e podemos concluir que:

$$g_{ms} = g_{mg} + g_{md} + g_{mb} \quad (2.4)$$

Logo, apenas 3 transcondutâncias são suficientes para caracterizar o comportamento de pequenos sinais em baixa frequência do MOSFET.

Figura 4 – Modelo ac do transistor MOSFET em baixas frequências



Fonte: (SCHNEIDER, 2010)

Dentre essas transcondutâncias, a mais relevante para este trabalho é a g_{mb} . A equação 2.5 nos mostra que g_{mb} é uma fração de g_{mg} , considerando que o fator de inclinação, n , apresenta valores no intervalo de 1.1 à 1.5 (SCHNEIDER, 2010). Este

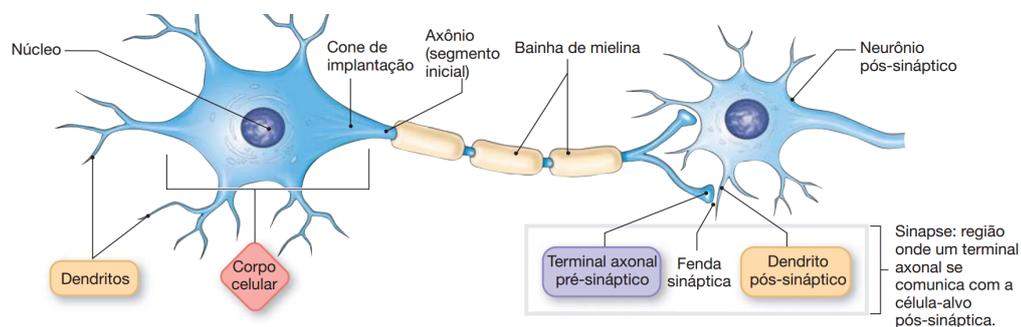
resultado possibilita a variação da tensão no substrato do transistor sem causar uma elevada variação na corrente do MOSFET, o que, por consequência, nos permite operar na faixa de frequência desejada.

$$g_{mb} = (n - 1)g_{mg} \quad (2.5)$$

2.3 Neurônios biológicos e sua dinâmica de funcionamento

Os neurônios são a unidade mais importante do sistema nervoso. Por sua causa, diversos sinais de tato, visão, audição, etc., podem ser obtidos, processados e nos permitir interagir com o mundo exterior. Resumidamente, o corpo celular de um neurônio é composto por um núcleo celular e organelas para direcionar as atividades celulares, semelhantes às outras células do corpo. Além disso, há dendritos e axônios, responsáveis pela comunicação entre neurônios. Os dendritos recebem o sinal elétrico, enquanto os axônios conduzem o sinal para outros neurônios (SILVERTHORN, 2017). A figura 5 mostra um desenho ilustrativo do neurônio.

Figura 5 – Representação de um neurônio



Fonte: (SILVERTHORN, 2017).

2.3.1 Canais e fluxo de íons através da membrana

A comunicação dos neurônios se dá através de estímulos elétricos, causados pelo movimento de íons, principalmente sódio (Na^+) e potássio (K^+). Esse movimento ocorre por diversos canais que se abrem e fecham ao longo da membrana do neurônio, dependendo das condições intra e extracelulares. Além disso, o conceito de condutância,

amplamente utilizado na eletrônica, se aplica aos canais da membrana e é representado pela letra G , indicando a facilidade com que os íons fluem através daquele canal. A condutância do canal varia com o estado de abertura deste e com a isoforma da proteína do canal. Os canais podem ser classificados em três categorias: canais iônicos controlados mecanicamente, canais iônicos dependentes de ligantes e canais iônicos dependentes de tensão.

Os canais de interesse para este trabalho são os dependentes de tensão. Esse tipo de canal apresenta respostas a mudanças no potencial de membrana do neurônio e possui grande relevância para a inicialização e condução de sinais elétricos ao longo do axônio.

O fluxo de íons ao longo da membrana tem direção, e essa direção depende do gradiente eletroquímico do íon. Por exemplo, Na^+ geralmente se move para fora da célula, enquanto K^+ se move para dentro da célula. Essa movimentação dos íons despolariza ou hiperpolariza a célula, gerando assim sinais elétricos. Esse fluxo de íons também pode ser chamado de corrente de íons, ou I_{ions} . Essa corrente, juntamente com a tensão ao longo da membrana e a condutância dos canais, obedece à lei de Ohm:

$$I_{ions} = V_{mem} \cdot G \quad (2.6)$$

ou também:

$$I_{ions} = \frac{V_{mem}}{R} \quad (2.7)$$

As mudanças de tensão que ocorrem ao longo da membrana celular podem ser classificadas em dois tipos: potenciais graduados e potenciais de ação. Neste trabalho, o potencial mais importante é o potencial de ação, que será explicado a seguir.

2.3.2 O potencial de ação

O potencial de ação representa um sistema de reforço baseado nas despolarizações da membrana celular do neurônio, mediadas por íons. Essa despolarização inicial gera um sinal elétrico, transmitido aos neurônios do estágio subsequente. Esses neurônios, por sua vez, podem despolarizar suas membranas, originando outro sinal elétrico que é então conduzido aos neurônios da camada seguinte. Esse processo prossegue em cascata até atingir o neurônio final (i.e, no córtex cerebral) e permite que o sinal chegue sem perda de intensidade (PURVES GEORGE J. AUGUSTINE, 2004).

O potencial de ação pode ser separado em fases, sendo elas: repouso, despolarização, polarização, hiperpolarização e pós-hiperpolarização. Na fase de repouso, o neurônio não recebe estímulos externos, e a tensão da membrana permanece constante em -70 mV.

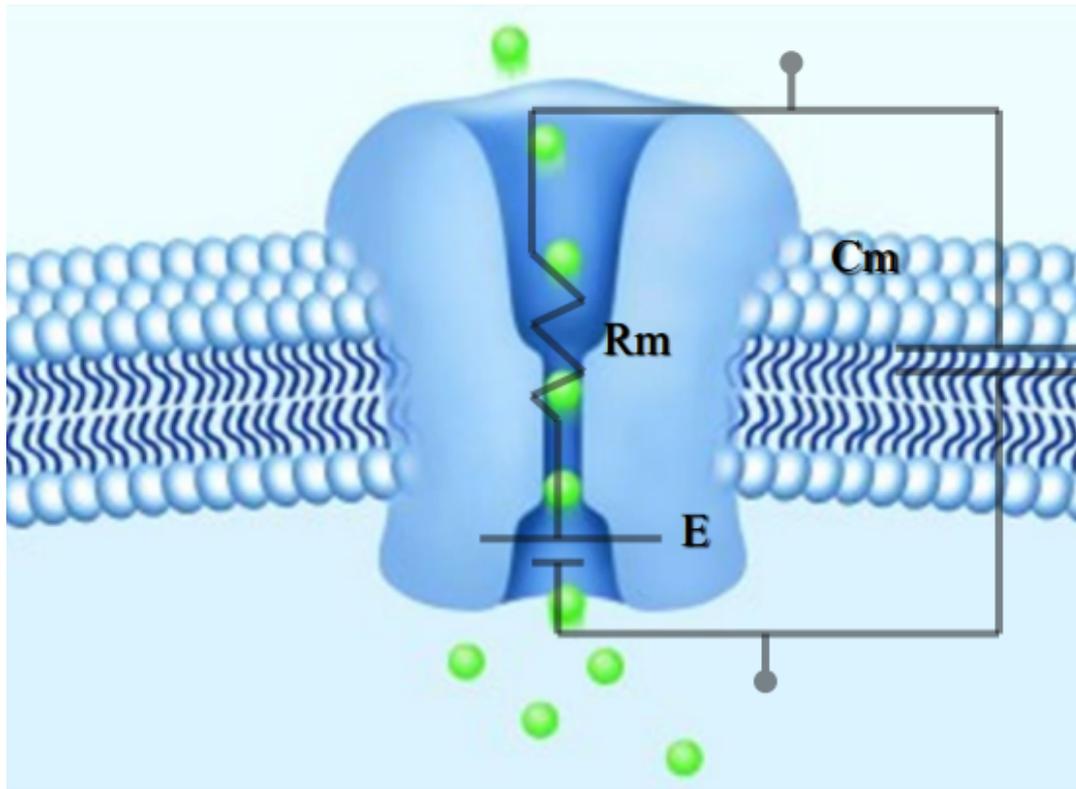
Quando a célula recebe um estímulo externo, a tensão de membrana, ou potencial de membrana, começa a aumentar e se mantém assim enquanto o estímulo externo persistir, entrando na fase de despolarização. O potencial de membrana é definido pelas diferenças de concentração de íons, como Na^+ , P^+ , Ca^+ e Cl^- entre os meios internos e externos de cada célula. Os gradientes de concentração através da membrana são estabelecidos por estruturas proteicas chamadas bombas de íons, que transportam essas cargas às custas de consumo de energia.

Durante a fase de despolarização, a tensão da membrana aumenta até atingir o limiar da célula, ou V_{th} . Nesse ponto, canais iônicos dependentes do potencial começam a se abrir, aumentando a permeabilidade da célula e permitindo a entrada de íons de sódio (Na^+). Isso inicia o processo de despolarização acelerada da membrana. A despolarização continua até a célula inverter sua polaridade, tornando seu interior mais positivo do que o exterior, e a tensão da membrana atinge +30 mV.

Quando isso ocorre, os canais de Na^+ se fecham, e os canais de K^+ , que respondem mais lentamente em comparação aos canais de Na^+ , se abrem. Com a saída de íons K^+ para o exterior, a célula volta a se polarizar até atingir seu potencial de repouso de -70 mV. No entanto, os canais de K^+ permanecem abertos, e a célula continua no processo de polarização, entrando na fase de hiperpolarização e chegando à tensão de -90 mV.

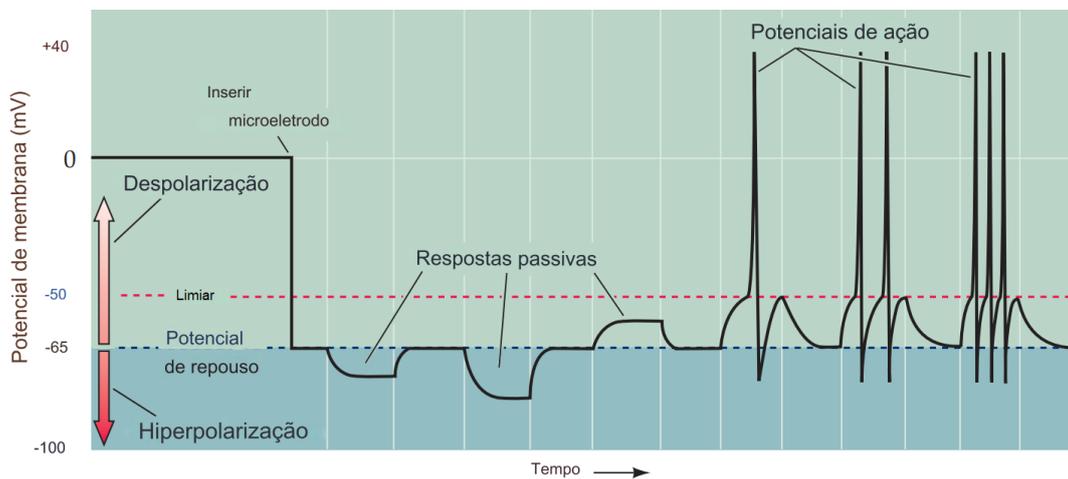
Finalmente, os canais de K^+ se fecham, e o vazamento de Na^+ para dentro da célula por meio da bomba de sódio e potássio faz a célula retornar ao seu equilíbrio, com potencial de membrana de -70 mV (SILVERTHORN, 2017). A figura 6 mostra uma representação ilustrativa da membrana celular e dos canais iônicos. E a figura 7 mostra as fases do potencial de ação por meio de um gráfico. É notável que, enquanto o potencial de membrana não atinge o limiar necessário, não ocorre o potencial de ação, e a tensão da membrana retorna ao seu estado de repouso. No entanto, ao superar o limiar, o potencial de ação é desencadeado, resultando em um disparo observável.

Figura 6 – Representação de um canal iônico



Fonte: (LEÃO, 2023).

Figura 7 – Fases do potencial de ação



Fonte: Adaptado de (PURVES GEORGE J. AUGUSTINE, 2004).

2.4 Modelo matemático do neurônio Integração e Disparo com Vazamento

O modelo de vazamento, integração e disparo, ou Leaky-Integrated-and-Fire (LIF), destaca-se por sua fácil implementação, refletida neste trabalho em um circuito com blocos simples, que demandam pouca área para serem integrados em um chip, consomem pouca energia para cada dado processado e proporcionam uma razoável aproximação do comportamento dos neurônios reais. Como mencionado anteriormente, o modelo de Hodgkin-Huxley é um dos modelos mais próximos da realidade, e o modelo LIF é um caso limite deste modelo (ELIASMITH, 2004). Portanto, também pode ser considerado biologicamente plausível. O LIF pode ser visto como um modelo que incorpora simplicidade e realismo no mesmo conjunto, como é mostrado na figura 8 (ELIASMITH, 2004).

O funcionamento do LIF pode ser explicado utilizando um circuito RC acoplado com um gerador de pulsos, ou função delta. Nessa configuração, o circuito RC tem a finalidade de modelar o comportamento passivo do neurônio, enquanto o gerador de pulso representa seu comportamento ativo. Juntos, esses circuitos têm o objetivo de simular a dinâmica temporal do potencial da membrana do neurônio.

O capacitor simula o acúmulo de cargas em ambos os lados da camada bilipídica que compreende a membrana de uma célula. Assim como não há movimento de cargas pela membrana lipídica, não há movimento de cargas através do capacitor. Em vez disso, temos uma alteração na quantidade de cargas separadas pelas placas do capacitor, resultando em uma corrente, aqui chamada de I_C . A corrente no capacitor pode ser expressa por uma equação diferencial, conforme mostrado abaixo.

$$V = \frac{Q}{C} \quad (2.8)$$

$$\frac{dQ}{dt} = I_C = C \cdot \frac{dV}{dt} \quad (2.9)$$

Assim como nas células ocorrem vazamentos de cargas devido ao efeito de algumas proteínas, como a bomba de sódio e potássio ATPase (SILVERTHORN, 2017), o resistor ligado em paralelo com o capacitor tem o objetivo de modelar esse efeito no neurônio LIF. Pela lei de Ohm, podemos determinar a expressão da corrente que passa pelo resistor:

$$I_R = \frac{V}{R} \quad (2.10)$$

Em um neurônio biológico, a corrente de entrada se dá pela soma de correntes pós-sinápticas geradas nos dendritos. Essa corrente pode ser separada em duas componentes,

a primeira chamada de componente estacionária, ou corrente de polarização, e a segunda chamada de componente de acionamento, que é responsável pelas rápidas flutuações de corrente devido às entradas dendríticas. No LIF, essas componentes da corrente de entrada podem ser representadas pelas correntes I_C e I_R . Como o fluxo de cargas deve ser conservado, podemos chegar na corrente da membrana, I_M , esta podendo ser expressa como:

$$I_M = I_C + I_R \quad (2.11)$$

Substituindo a equação 2.9 e 2.10 em 2.11 e rearranjando os termos, temos:

$$I_M = C \cdot \frac{dV}{dt} + \frac{V}{R} \quad (2.12)$$

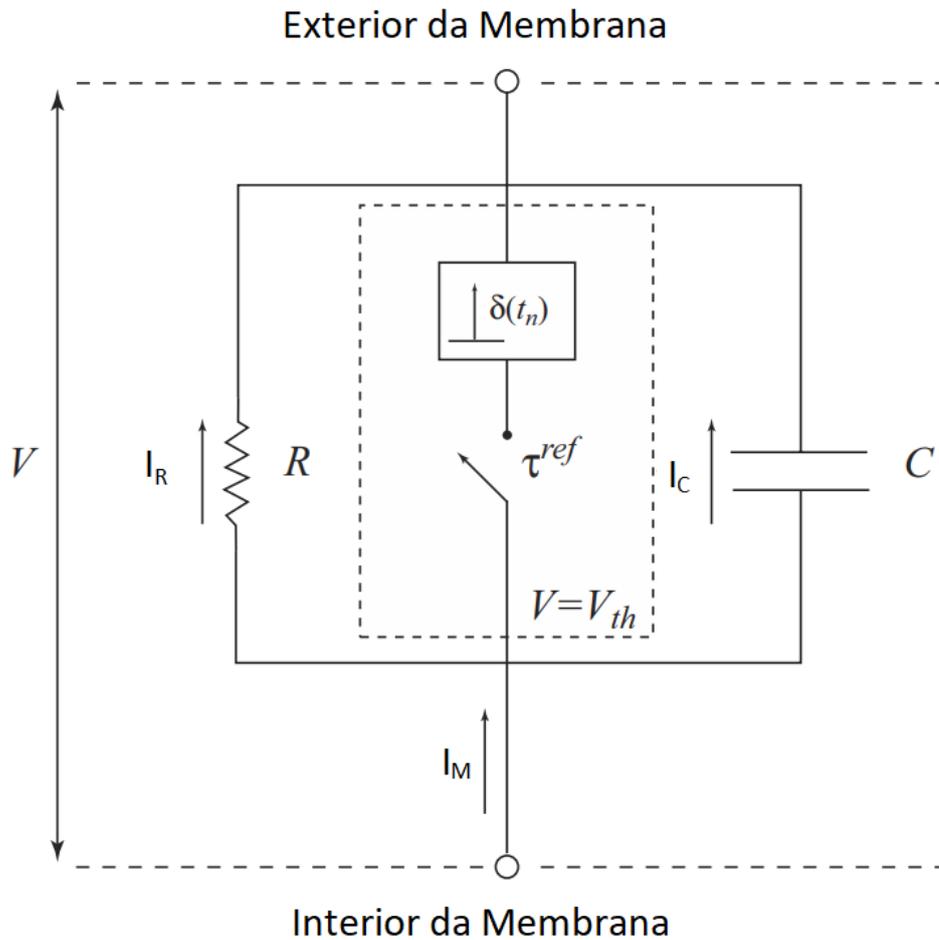
$$\frac{dV}{dt} = -\frac{1}{\tau^{RC}} \cdot (V - I_M R) \quad (2.13)$$

Sendo $\tau^{RC} = RC$. As equações acima representam o comportamento passivo dos neurônios.

A segunda parte do circuito é responsável pelo modelamento ativo do neurônio LIF. Com o acúmulo de cargas no capacitor, que aumenta à medida que a corrente pós-sináptica entra no neurônio, temos também um valor de potencial de membrana cada vez maior. Esse potencial sobe até atingir o potencial de limiar do neurônio, V_{th} . Quando esses valores de potenciais se cruzam, um canal interno do neurônio se fecha, ativando o gerador de pulsos. Com isso, um pulso é gerado na saída, e o neurônio tem seu valor de potencial de membrana zerado, permanecendo assim por um período de tempo τ^{ref} . Após esse período, o canal se abre, e o processo se repete. Esse período, τ^{ref} , é igual ao período refratário absoluto do neurônio modelado.

As figuras 8 e 9 demonstram todos os componentes do modelo e a dinâmica da tensão da membrana para uma corrente constante. Pode-se observar o resistor e o capacitor, responsáveis pelo modelamento passivo, e ao centro da figura, o gerador de pulsos, responsável pelo comportamento ativo. Percebe-se que este está dentro de um retângulo tracejado, indicando sua separação dos componentes passivos, e que apenas é ativado quando $V = V_{th}$. A segunda figura demonstra o comportamento da tensão da membrana ao receber um estímulo de corrente constante. Pode ser observado que a tensão da membrana sobe até atingir a tensão de limiar do neurônio, e então um disparo é gerado; a tensão da membrana é rapidamente descarregada e permanece assim por um período, chamado período refratário.

Figura 8 – Circuito equivalente do modelo LIF para neurônios



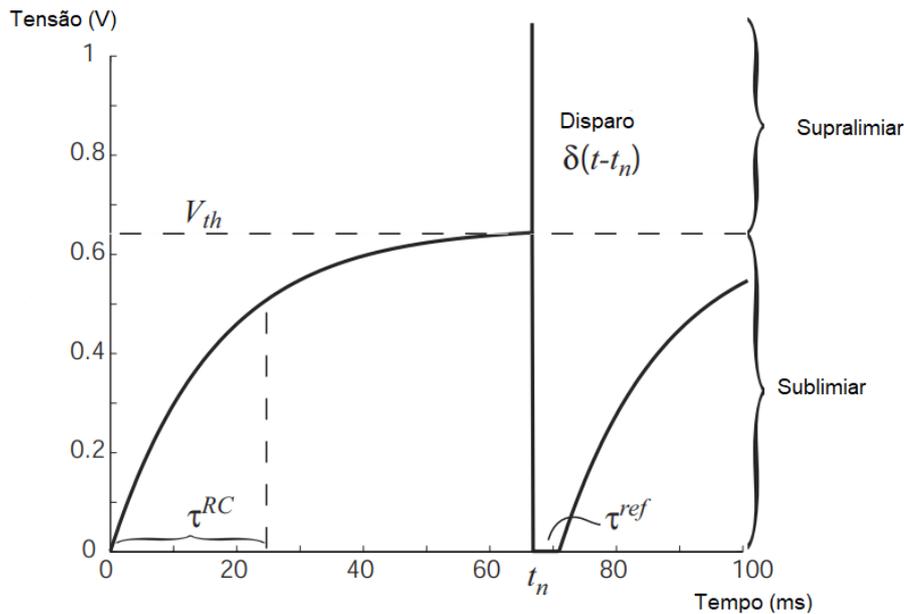
Fonte: Adaptado de (ELIASMITH, 2004).

2.5 Modelo LIF em circuito integrado

Com base no modelamento matemático do LIF, é possível chegar a um circuito integrado que se comporte da mesma maneira. O circuito utilizado neste trabalho tem como base o desenvolvido por (YANG et al., 2020), com algumas alterações necessárias que serão explicadas no decorrer do texto.

Como explicado anteriormente, o modelo LIF deve apresentar uma fonte de corrente, para gerar o acúmulo de cargas e iniciar o processo de disparo, uma capacitância, para simular o acúmulo de cargas na membrana, um resistor, para simular o vazamento de cargas contínuo, e um gerador de pulso que é ativado quando o valor do potencial de membrana atinge um valor de limiar. Felizmente, todos esses componentes podem ser

Figura 9 – Comportamento da tensão de membrana para uma corrente constante

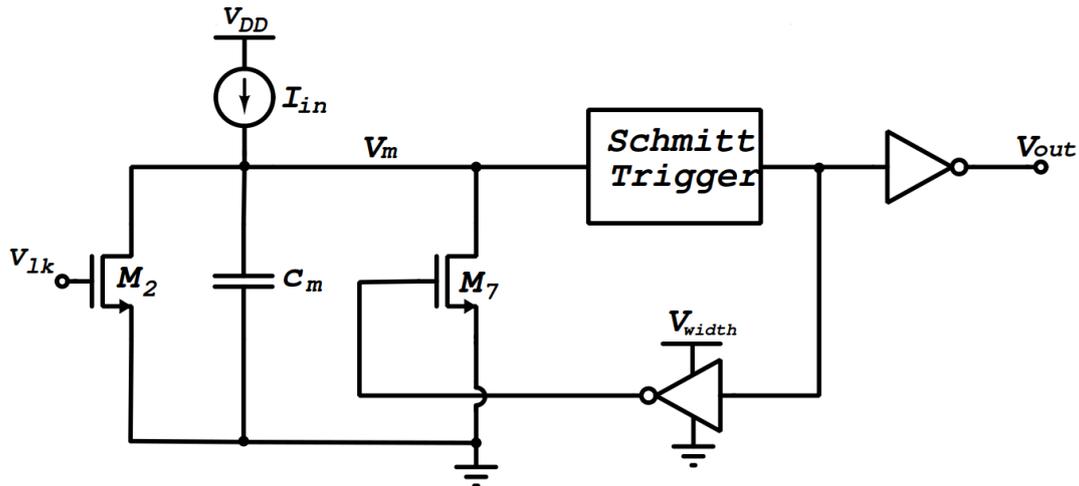


Fonte: Adaptado de (ELIASMITH, 2004).

obtidos em um circuito integrado. A fonte de corrente utilizada é um transistor que tem sua tensão de substrato variável, para gerar os *intercepts*. Para minimizar problemas de variações de processos, a tensão de porta é fixada por um espelho de corrente. Os capacitores são facilmente implementados com duas camadas de metal-isolante-metal, os resistores são implementados com uma trilha geralmente de polissilício, por apresentar maior resistência se comparado ao resistores metálicos, de nwell ou difusão P ou N, ou podem ser implementados utilizando transistores na região triodo. Para este trabalho, foi escolhida a segunda opção, pois resistores, além de ocuparem grandes áreas em silício, sofrem mais com variações de processos na fabricação. Utilizando transistores, a área ocupada é drasticamente reduzida, e tem-se um controle maior dos parâmetros que variam com os processos de fabricação. Por último, o gerador de pulsos, que pode ser implementado com um comparador Schmitt Trigger, um comparador com histerese que muda rapidamente sua saída de Ground para VDD, ou vice versa, quando a tensão de entrada ultrapassa um valor de limiar. A figura 10 mostra o esquemático simplificado do neurônio.

Considerando uma capacitância C_m em paralelo com um transistor M1, operando na região triodo, e uma corrente pós-sináptica I_{in} de entrada, podemos escrever a seguinte igualdade:

Figura 10 – Esquemático simplificado do modelo LIF



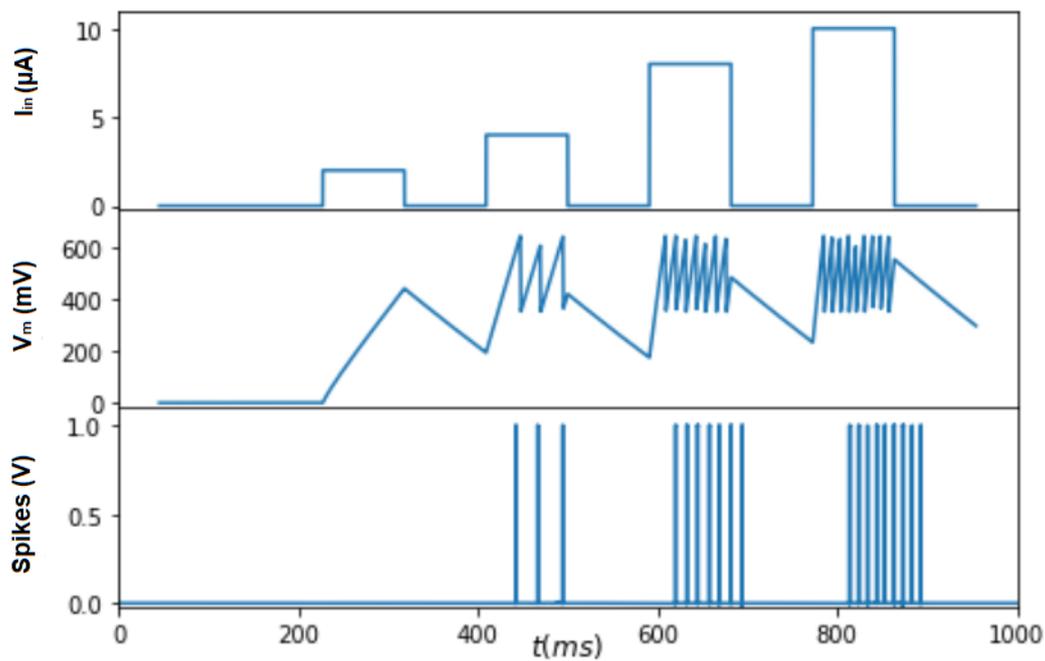
Fonte: Autor.

$$I_{in} = C_m \frac{dV_m}{dt} + g(V_m - V_{reset}) \quad (2.14)$$

onde g é a condutância que fornece o vazamento de corrente implementada pelo transistor M_2 . Essa condutância é controlada pela tensão V_{lk} , que controla a tensão de porta-fonte, V_{GS} (YANG et al., 2020). Com a entrada da corrente I_{in} no circuito, o capacitor integrará a corrente e, por consequência, a tensão V_m irá aumentar. Enquanto há corrente entrando no circuito, V_m continua aumentando, até que seu valor alcance a tensão de limiar do comparador. Quando isso ocorre, o comparador é ativado e muda bruscamente sua saída. Essa mudança passa por um inversor que ativa a chave M_7 , causando um curto-circuito entre o nó V_m e o GND, e com isso, o capacitor é rapidamente descarregado, e a tensão V_m é rapidamente diminuída. A tensão de alimentação do inversor que ativa a chave M_7 é denominada V_{width} e seu valor determina a velocidade com que o capacitor C_m é descarregado. Quanto menor for V_{width} , menor será a tensão V_{GS} de M_7 e, por consequência, o tempo de descarga do capacitor será maior. Na saída do comparador, também é colocado outro inversor, que tem a finalidade de gerar um pulso quando a tensão de limiar é alcançada. O processo irá se repetir enquanto houver corrente entrando no neurônio. Se, inicialmente, houver corrente entrando no circuito e, em seguida, for interrompida, a tensão de membrana diminuirá gradualmente devido ao vazamento provocado pelo transistor M_2 . A figura 11 mostra esse comportamento através de três gráficos, corrente de entrada, tensão da membrana e disparos na saída do neurônio. Ao se aplicar um sinal de corrente, denominado I_{in} , por um determinado de

tempo, eixo x do gráfico, e determinada amplitude, a tensão da membrana, V_m , aumenta por conta do acúmulo de cargas no capacitor. Caso o sinal de corrente seja interrompido antes que V_m alcance o limiar do comparador, V_m começa a decair por conta do vazamento de corrente, implementado pelo transistor M2. Caso o sinal de corrente seja aplicado por um período de tempo maior ou com maior amplitude, invariavelmente V_m atingirá a tensão de limiar do comparador, gerando, assim, um pulso na saída do neurônio.

Figura 11 – Comportamento do modelo LIF ao longo do tempo para uma entrada $I_i n$ de corrente



Fonte: Adaptado de (YANG et al., 2020).

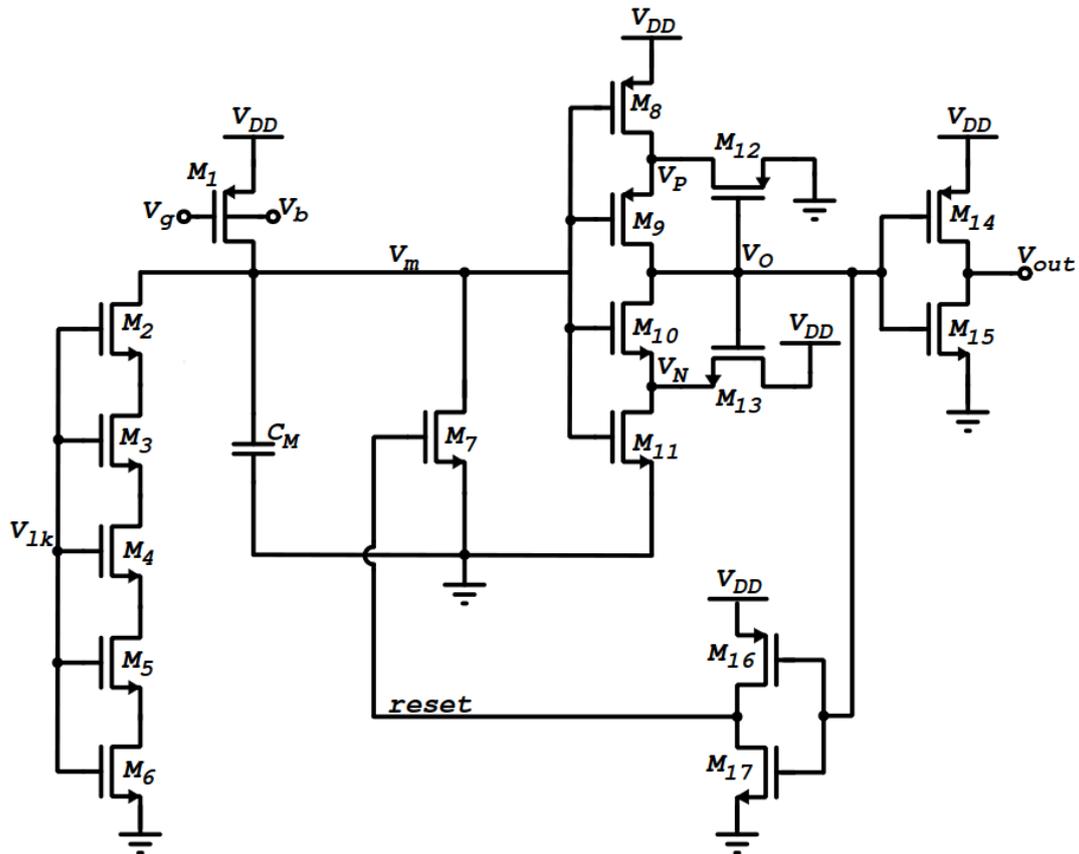
3 Projeto

O propósito deste projeto é criar um neurônio modelo de vazamento, integração e disparo capaz de replicar o comportamento entrada x frequência, assemelhando-se à biblioteca NENGO. Para alcançar esse objetivo, foi essencial desenvolver não apenas o neurônio em si, mas também um circuito auxiliar responsável por converter uma entrada linear em não linear.

3.1 Neurônio

O neurônio foi desenvolvido com base no trabalho (YANG et al., 2020).

Figura 12 – Esquemático do neurônio



Fonte: Autor.

Como dito anteriormente, para simular um neurônio é necessário ter elementos passivos responsáveis por simular a tensão de membrana e os vazamentos gerados pelos canais iônicos, e um elemento ativo que gerará o pulso quando a tensão da membrana alcançar determinado limiar. Para isso, neste trabalho, o capacitor C_m e os transistores ligados em série, M2-6, operando na região de triodo, simulam os elementos passivos do neurônio.

O componente ativo incorpora um comparador Schmitt Trigger com histerese definido em $V_H = 467$ mV. Os limiares são estabelecidos em 717 mV para o superior ou (V_{SPH}) e 250 mV para o inferior ou (V_{SPL}). A figura 13 mostra a curva de entrada e saída do Schmitt Trigger, onde é apresentado, em vermelho, o sinal de entrada e em marrom o sinal de saída. Para determinar os limiares superiores e inferiores as equações 3.1, 3.2 e 3.3 foram utilizadas (BAKER, 2019).

$$V_H = V_{SPH} - V_{SPL} \quad (3.1)$$

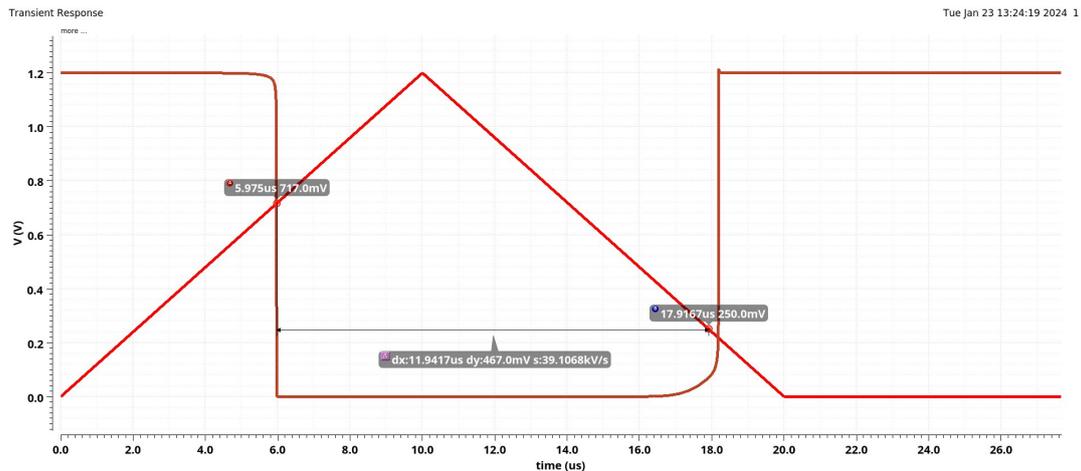
$$\frac{\beta_1}{\beta_3} = \frac{W_1 \cdot L_3}{W_3 \cdot L_1} = \left(\frac{V_{DD} - V_{SPH}}{V_{SPH} - V_{THN}} \right)^2 \quad (3.2)$$

$$\frac{\beta_5}{\beta_6} = \frac{W_5 \cdot L_6}{W_6 \cdot L_5} = \left(\frac{V_{SPL}}{V_{DD} - V_{SPH} - V_{THP}} \right)^2 \quad (3.3)$$

sendo β_1 , β_3 , β_5 e β_6 as relações de aspecto dos transistores.

A saída do comparador é conectada a dois inversores, sendo um responsável por gerar o pulso na saída do neurônio e outro responsável por ligar a chave M7, que curto-circuita o capacitor ao terra, permitindo assim sua descarga e reinício do processo.

Figura 13 – Sinais de entrada e saída do comparador Schmitt Trigger



Fonte: Autor.

O transistor M1 é responsável por injetar corrente no circuito e carregar o capacitor. Sua tensão de porta é definida por um espelho de corrente e a tensão aplicada no substrato vem do circuito auxiliar, que será abordado a seguir, e permite simular as curvas observadas na biblioteca NENGO. Isso é necessário para controlar a transcondutância de substrato, que permite maior controle sobre a corrente que entra no circuito.

Neste circuito, é possível controlar o vazamento de corrente pela tensão de porta V_{lk} e como dito anteriormente V_{width} é a tensão de alimentação do inversor composto por M16 e M17, que ativa o transistor M7, responsável por descarregar o capacitor C_m . A variação em V_{width} impacta diretamente no tempo de descarga do capacitor C_m , controlando a rapidez desse processo. V_{width} menor resulta em uma diminuição na tensão V_{GS} de M7 e, conseqüentemente, em um aumento no tempo de descarga do capacitor, que por sua vez gera um pulso na saída prolongado. Neste trabalho, V_{width} é fixado em V_{DD} como pode ser visto na figura 12.

A principal diferença entre este trabalho e o trabalho de (YANG et al., 2020) são os valores de capacitâncias utilizadas. Neste trabalho, é utilizado um capacitor de 476 fF, que pode ser facilmente integrado junto dos outros componentes do neurônio. Mesmo com uma capacitância baixa, foi possível cobrir a faixa de frequência usada pela SNN simulada no NENGO. Enquanto no trabalho (YANG et al., 2020), os pesquisadores utilizaram um capacitor de 300 nF, o que torna inviável a integração completa do neurônio.

Porém, para utilizar uma capacitância tão baixa e alcançar a faixa de frequência desejada, foi necessário trabalhar com correntes na casa das dezenas a centenas de pA, o que dificulta o controle. E, por se tratar de uma corrente de magnitude tão pequena,

Transistor	W (μm)	L (μm)
M1	0.2	12
M2-6	1	3
M7	1	0.1
M8	0.4	2
M9	2	0.260
M10	8	0.260
M11	3	0.4
M12	4	0.180
M13	0.2	3
M14, M16	0.6	0.065
M15, M17	0.2	0.065

Tabela 1 – Dimensões dos transistores do neurônio

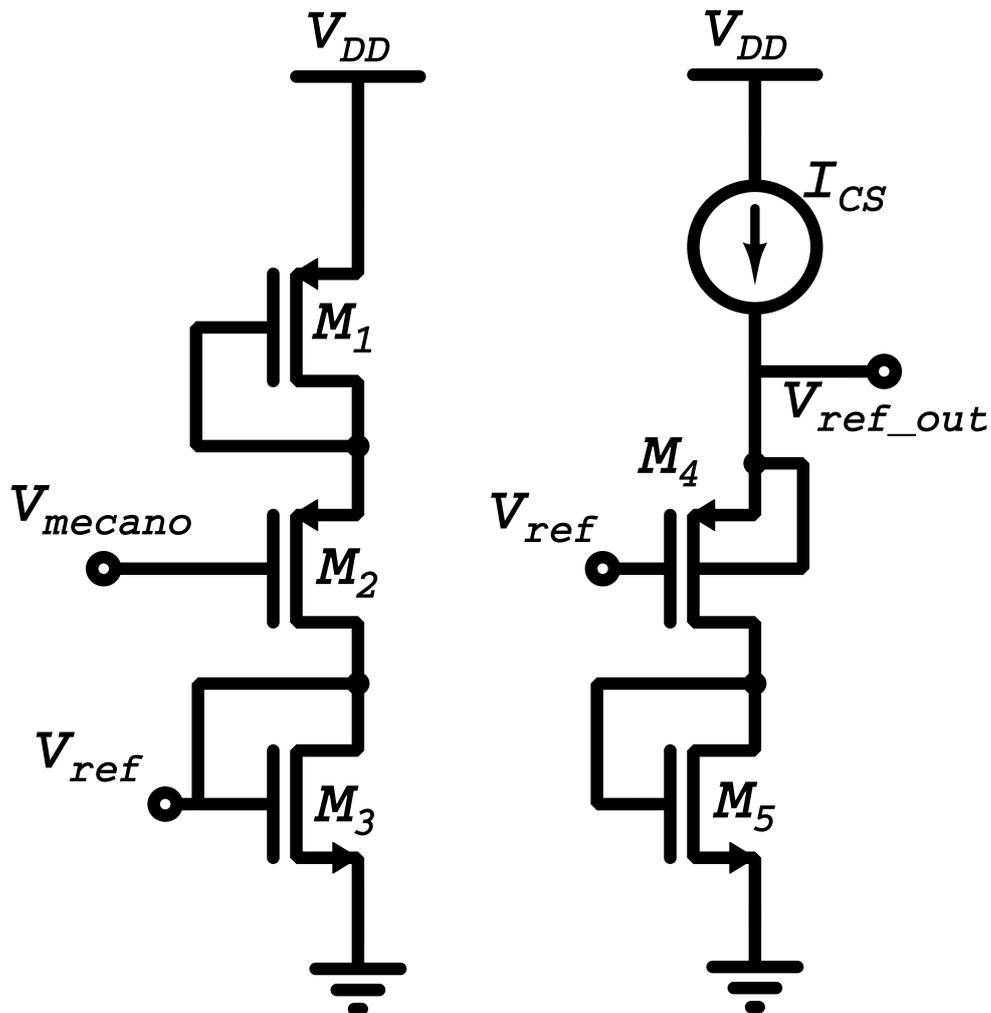
qualquer fuga de corrente que não seja proposital é indesejado. Para minimizar essas fugas, os transistores M8-11 são de óxido espesso. A figura 12 mostra o esquemático do neurônio, e a tabela 1 apresenta as dimensões dos transistores. A tecnologia utilizada foi CMOS 65 nm.

3.2 Circuito auxiliar

Para produzir respostas similares às curvas de *intercepts* implementadas pela biblioteca NENGO, é necessário aplicar um sinal não linear no neurônio. A figura 1 mostra as características dos *intercepts*. É possível perceber que para o mesmo valor de entrada, os neurônios podem responder em frequências diferentes.

O circuito que implementa essa curva é mostrado na figura 14. A tensão V_{mecano} é uma rampa, que parte de 350 mV e vai até 1.2 V para os *intercepts* positivos e partindo de 0 V e vai até 1.15 V para os *intercepts* negativos. Inicialmente, M2 se encontra em saturação e permite que a corrente flua através de M1 e M3. No entanto, a variação de V_{mecano} gera uma variação em V_{GS} de M1. E pela relação exponencial entre I_D e V_{GS} , conseguimos uma variação em V_{ref} não linear, o que nos permite gerar as curvas de entrada x frequência similares às do NENGO. A tensão V_{ref} passa por um seguidor de fonte implementado com o transistor M4, para que seu nível de tensão seja deslocado para cima. A tabela 2 a seguir mostra as dimensões dos transistores, e a figura 16 mostra a tensão V_{ref} .

Transistor	W (μm)	L (μm)
M1	0.5	2x6
M2	0.5	7x10
M3	0.5	5x20
M4	6	0.065
M5	0.5	6

Tabela 2 – Dimensões dos transistores do circuito para geração dos *intercepts* positivosFigura 14 – Esquemático do circuito auxiliar para geração de *intercepts* positivos

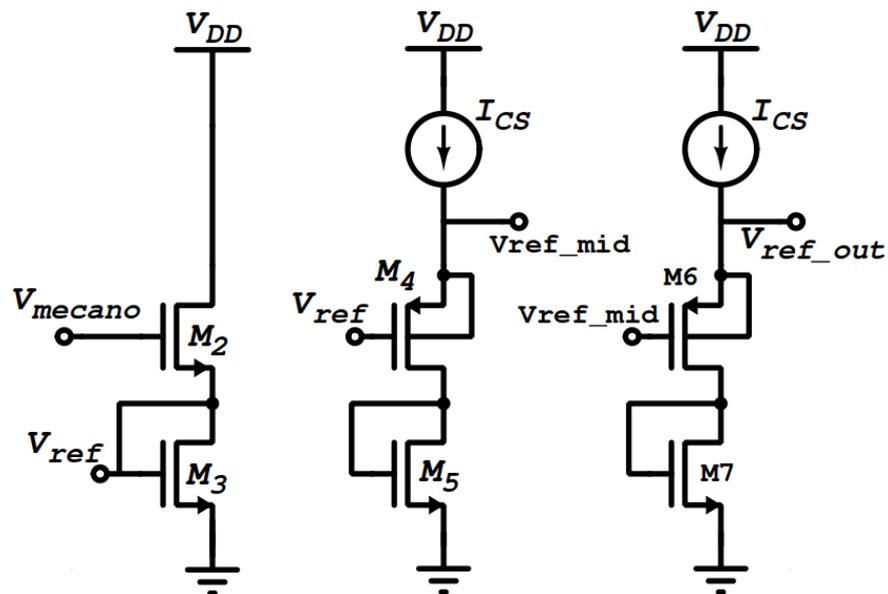
Fonte: Autor.

Para obter os *intercepts* negativos o mesmo circuito é utilizado, porém o transistor M_2 é trocado por um NMOS e é necessário acrescentar mais um estágio de seguidor de fonte, como mostrado na figura 15. A relação de aspecto dos transistores são mostradas

Transistor	W (μm)	L (μm)
M2	0.2	7x20
M3	10	5x0.5
M4, M6	20	0.065
M5, M7	2	2

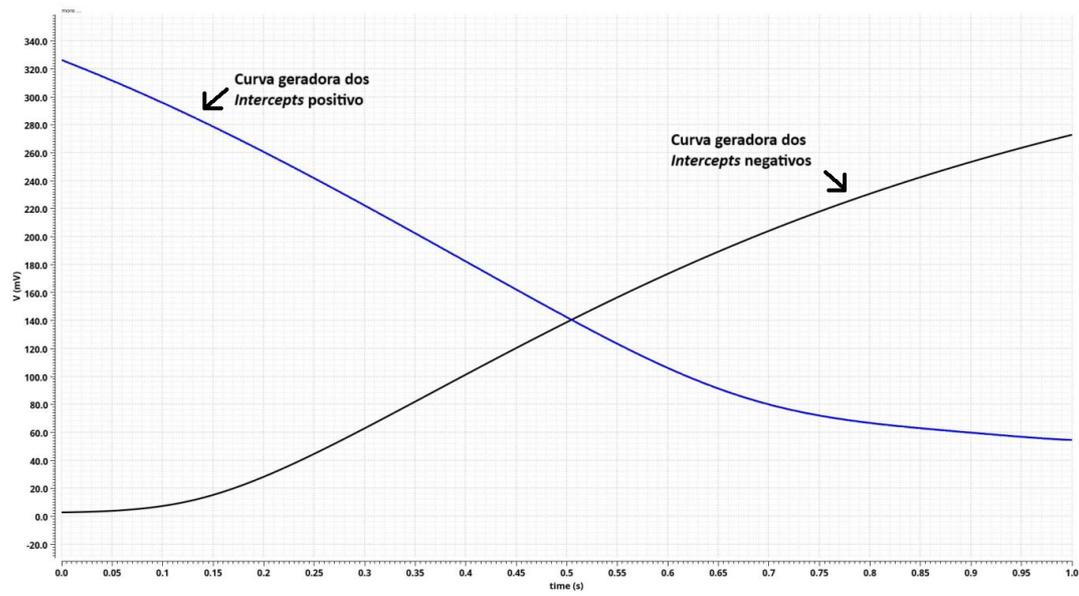
Tabela 3 – Dimensões dos transistores do circuito para geração de *intercepts* negativos na tabela 3.

Figura 15 – Esquemático do circuito auxiliar para geração dos *intercepts* negativos



Fonte: Autor.

Figura 16 – Resposta dos circuitos não lineares



Fonte: Autor.

4 Resultados

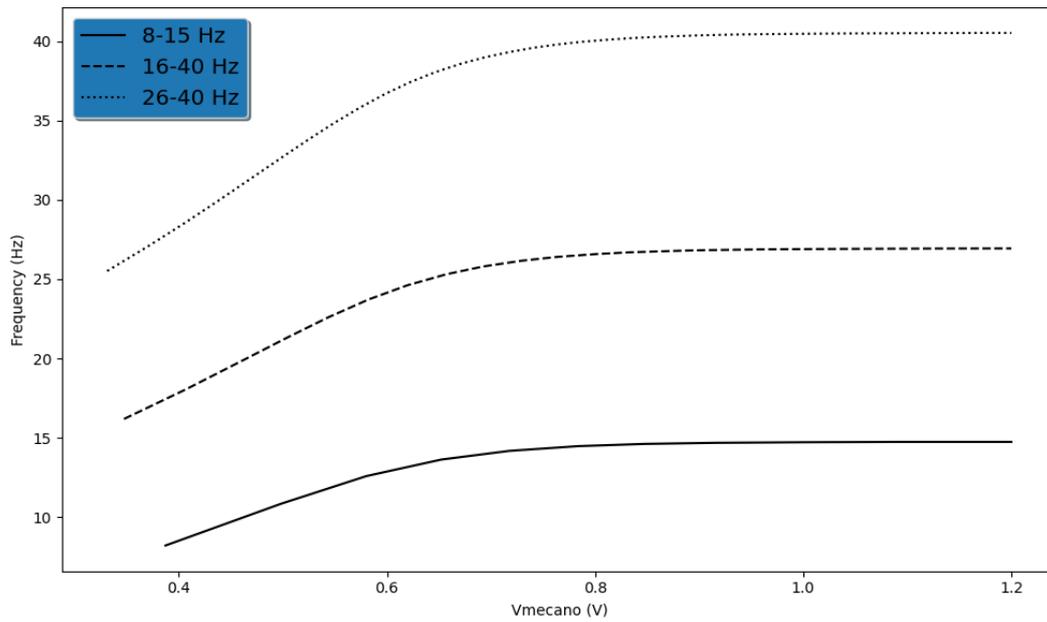
4.1 *Intercepts* e frequência de disparo

Nesta seção apresentaremos os resultados obtidos em simulação, com o neurônio configurado para gerar os *Intercepts* positivos e negativos.

Aplicando-se uma rampa que aumenta linearmente ao longo de um segundo, identificada como V_{mecano} no esquemático do circuito auxiliar, é possível gerar a curva exponencial, marcada como V_{refout} também no esquemático do circuito auxiliar. A saída do circuito auxiliar é conectada ao substrato do transistor M1 no esquemático do neurônio fazendo com que g_{mb} varie e injete corrente no neurônio. Utilizar g_{mb} é vantajoso, pois esta transcondutância é apenas uma fração de g_m e isso permite ter um controle maior da frequência de operação do neurônio, já que a frequência depende da corrente de entrada e esta corrente está na casa dos pA, que torna o controle de frequência pela transcondutância g_m impraticável.

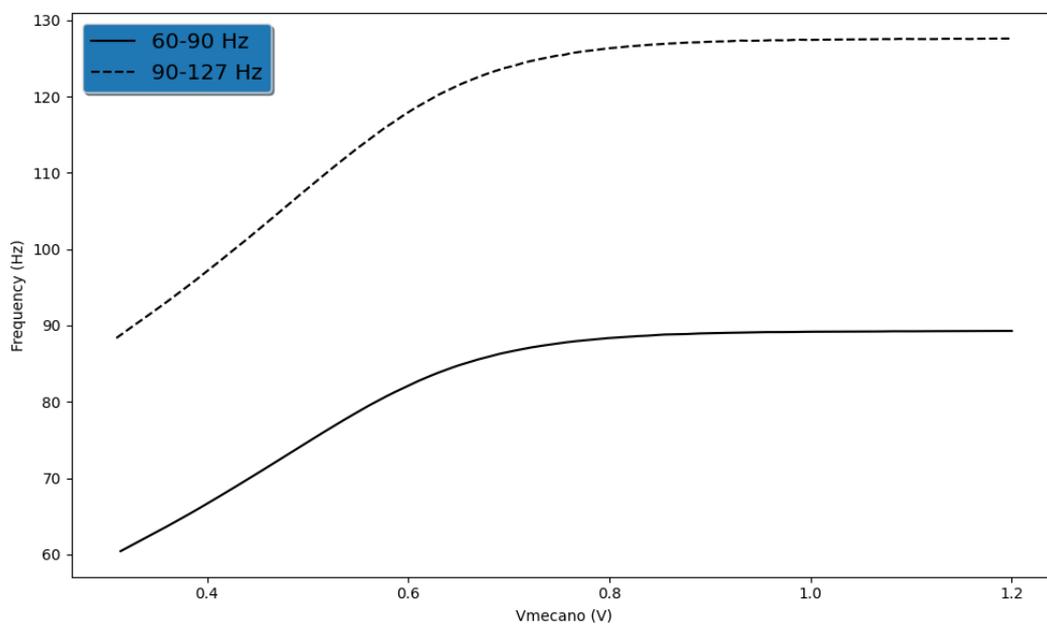
Para os *Intercepts* positivos, a faixa de frequência alcançada varia entre 8 Hz e 408 Hz. Além disso, são apresentadas as tensões da membrana, identificadas como V_m no esquemático, permitindo a visualização do aumento da frequência de disparo. Este aumento também pode ser observado nos próprios disparos na saída do neurônio, identificados como V_{out} no esquemático. As figuras 17, 18 e 19 mostram as frequências de disparo pela tensão de entrada, V_{mecano} . Podemos visualizar o aumento da frequência de disparo com o aumento do valor de V_{mecano} . Para gerar estas curvas com frequências diferentes, foi necessário alterar a corrente de entrada do neurônio e para tal, a relação de aspecto entre M1 e o transistor ligado a ele, que está configurado como diodo, é alterada.

Figura 17 – *Intercepts* positivos, com intervalos de frequência de 8 à 15 Hz, 16 à 40 Hz e 26 à 40 Hz



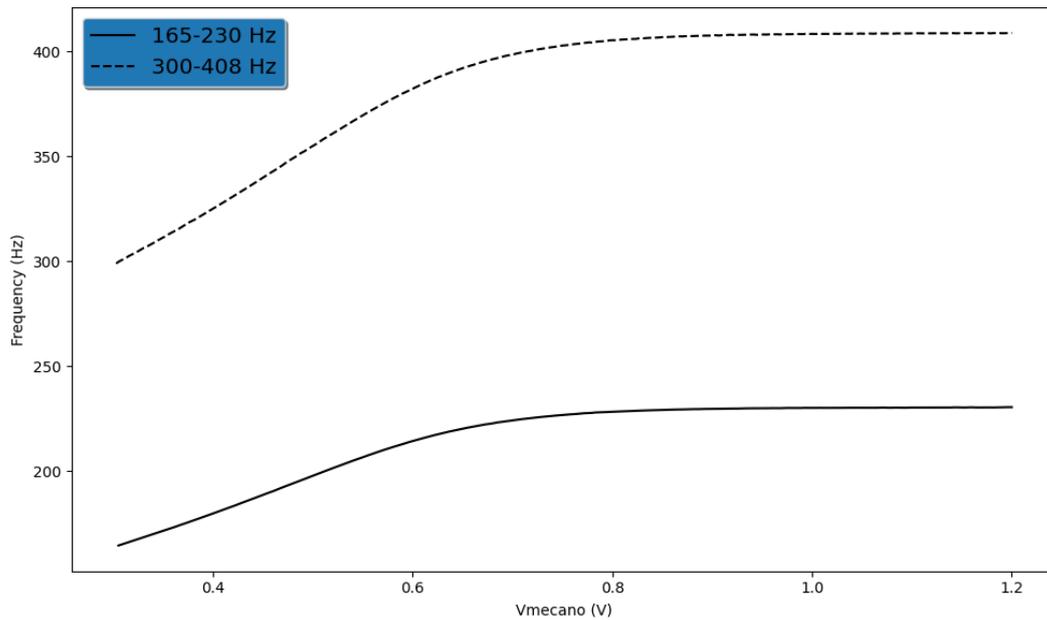
Fonte: Autor.

Figura 18 – *Intercepts* positivos, com intervalos de frequência de 60 Hz á 90 Hz e 90 à 127 Hz



Fonte: Autor.

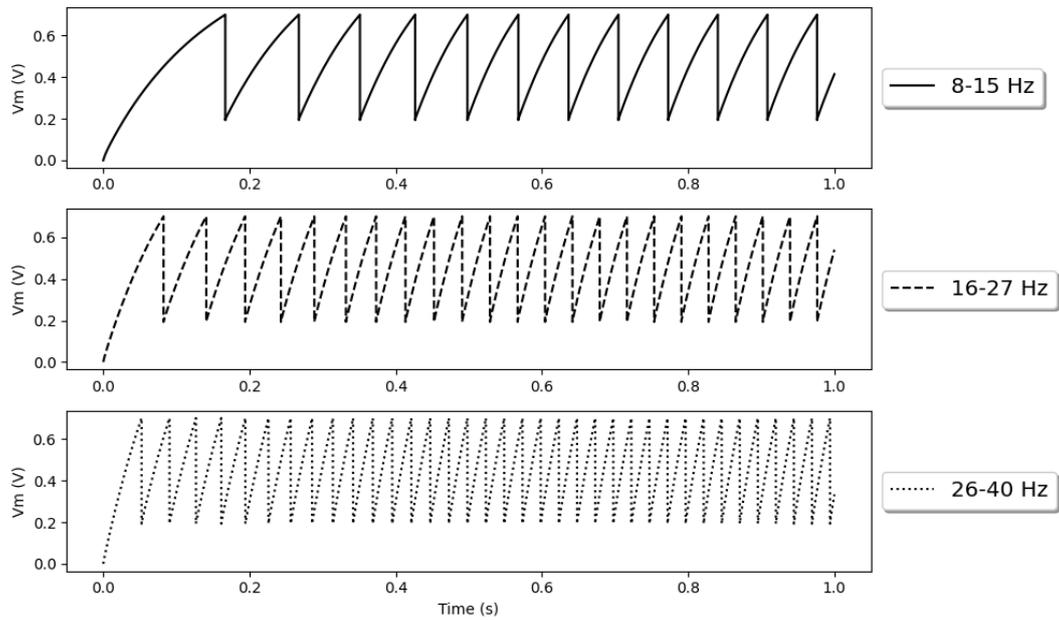
Figura 19 – *Intercepts* positivos, com intervalos de frequência de 165 Hz á 230 Hz e 300 à 408 Hz



Fonte: Autor.

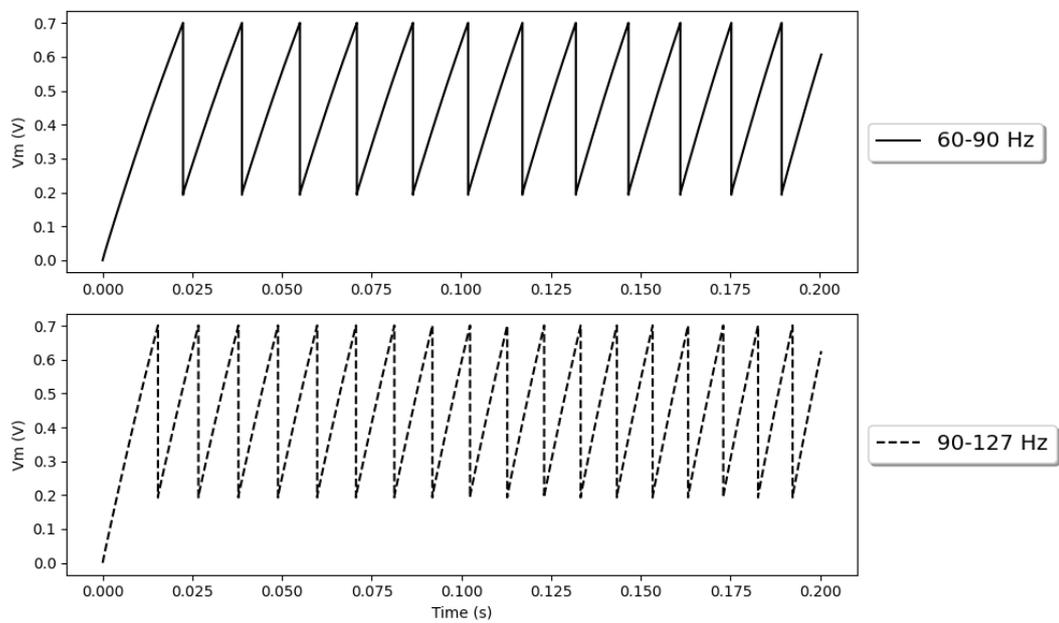
As figuras 20, 21 e 22 mostram a tensão da membrana, ou V_m no esquemático do neurônio, no intervalo de um segundo. Para as frequências de disparo acima de 60 Hz foi feito um recorte de tempo para melhor visualização. Podemos visualizar o aumento na frequência da tensão da membrana da esquerda para a direita, causada pelo aumento da tensão V_{mecano} .

Figura 20 – Tensão da membrana, V_m , para os *Intercepts* positivos, com intervalos de frequência de 8 à 15 Hz, 16 à 40 Hz e 26 à 40 Hz



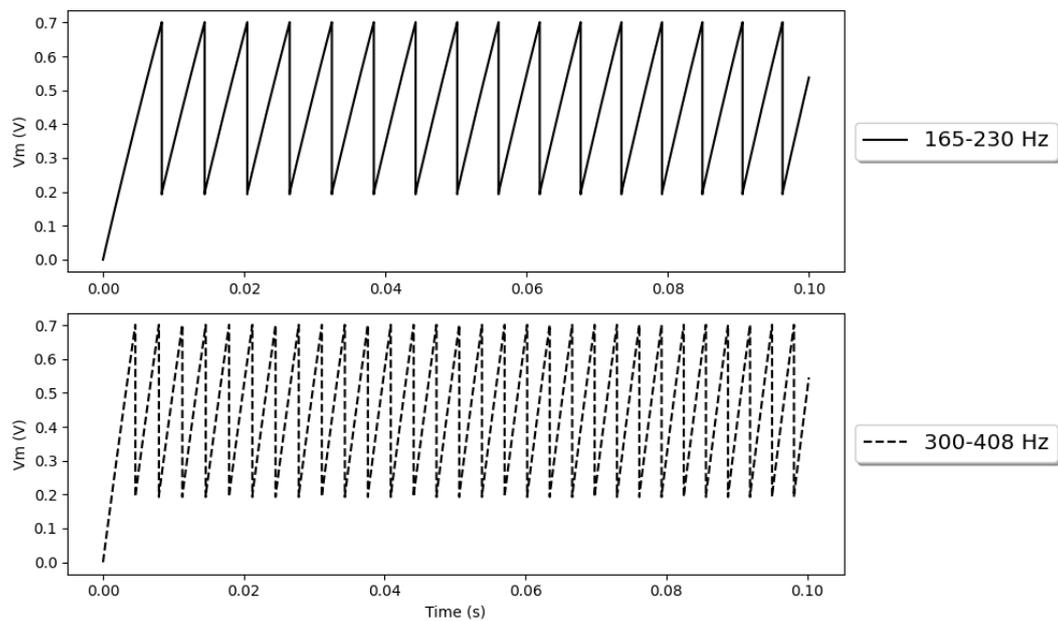
Fonte: Autor.

Figura 21 – Tensão da membrana, V_m , para os *Intercepts* positivos, com intervalos de frequência de 60 Hz à 90 Hz e 90 à 127 Hz



Fonte: Autor.

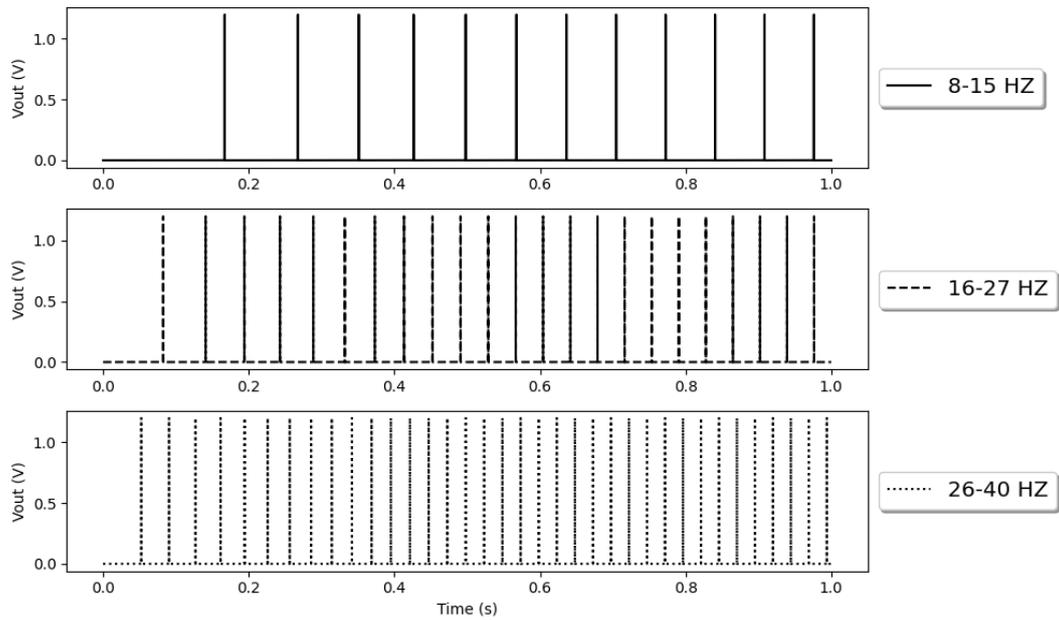
Figura 22 – Tensão da membrana, V_m , para os *Intercepts* positivos, com intervalos de frequência de 165 Hz á 230 Hz e 300 à 408 Hz



Fonte: Autor.

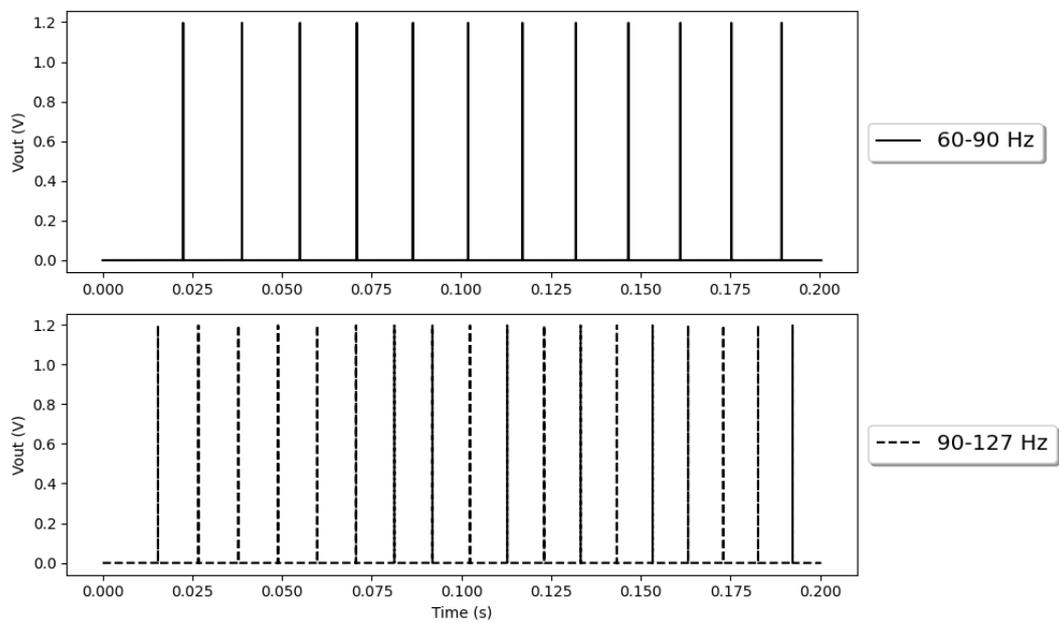
As figuras 23, 24 e 25 mostram os disparos na saída do neurônio, ou V_{out} no esquemático do neurônio, no intervalo de um segundo. Para as frequências de disparo acima de 60 Hz foi feito um recorte de tempo para melhor visualização. Novamente podemos visualizar o aumento da frequência de disparo da esquerda para a direita, seguindo o comportamento da tensão V_{mecano} que também aumenta ao longo do tempo.

Figura 23 – Disparos na saída, V_{out} , para os *Intercepts* positivos, com intervalos de frequência de 8 à 15 Hz, 16 à 40 Hz e 26 à 40 Hz



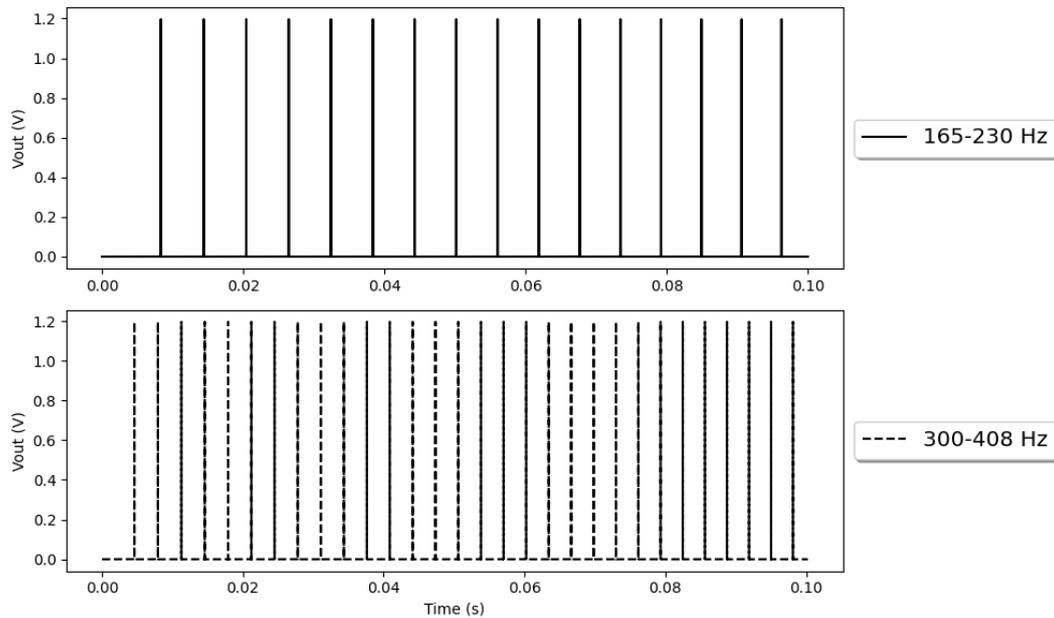
Fonte: Autor.

Figura 24 – Disparos na saída, V_{out} , para os *Intercepts* positivos, com intervalos de frequência de 60 Hz à 90 Hz e 90 à 127 Hz



Fonte: Autor.

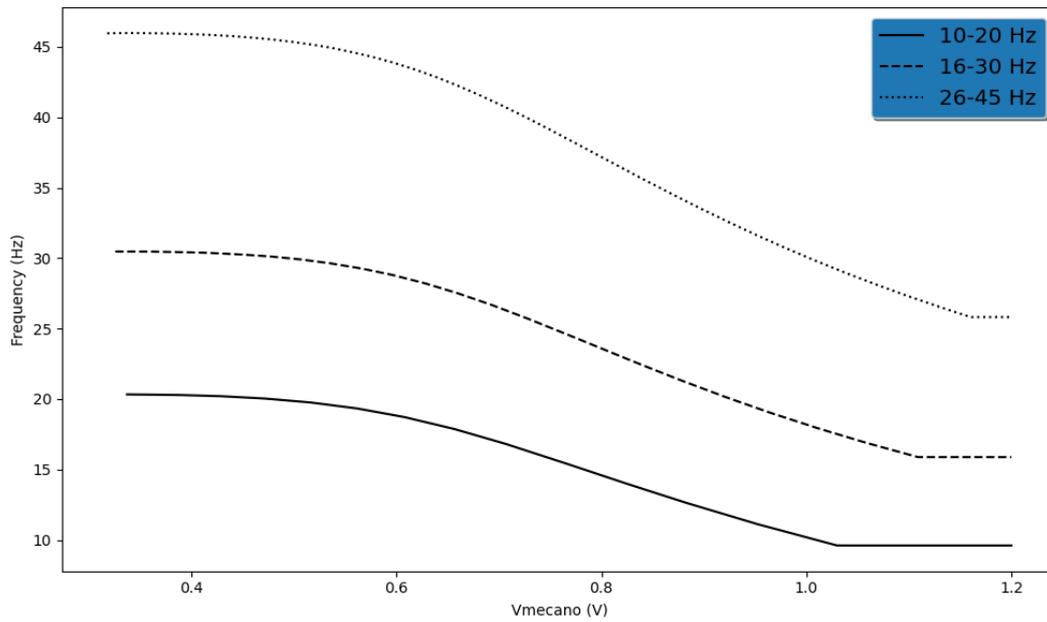
Figura 25 – Disparos na saída, V_{out} , para os *Intercepts* positivos, com intervalos de frequência de 165 Hz à 230 Hz e 300 à 408 Hz



Fonte: Autor.

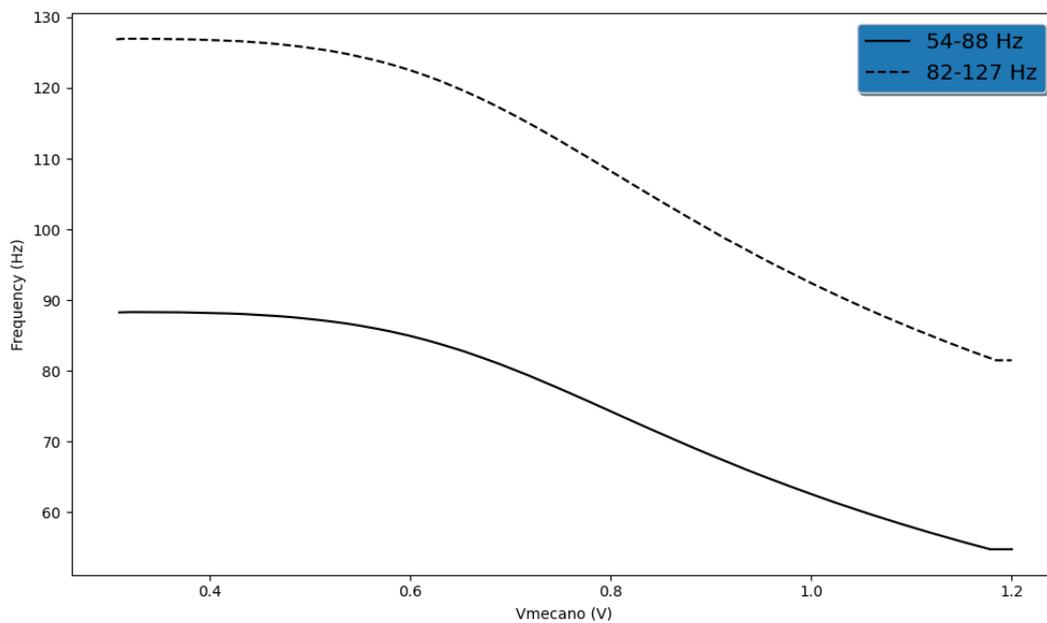
Agora mostraremos os resultados dos *Intercepts* negativos. A faixa de frequência alcançada varia entre 10 Hz e 414 Hz. As figuras 26, 27 e 28 mostram a frequência de disparo pela tensão de entrada, V_{mecano} . Agora podemos visualizar a diminuição da frequência de disparo com o aumento do valor de V_{mecano} , se opondo ao comportamento observado nos *Intercepts* positivos. Novamente, para gerar estas curvas com frequências diferentes, foi necessário alterar a corrente de entrada do neurônio e para tal, novamente, a relação de aspecto entre M1 e o transistor ligado a ele, configurado como diodo, é alterada.

Figura 26 – Disparos na saída, V_{out} , para os *Intercepts* negativos, com intervalos de frequência de 10 à 20 Hz, 16 à 30 Hz e 26 à 45 Hz



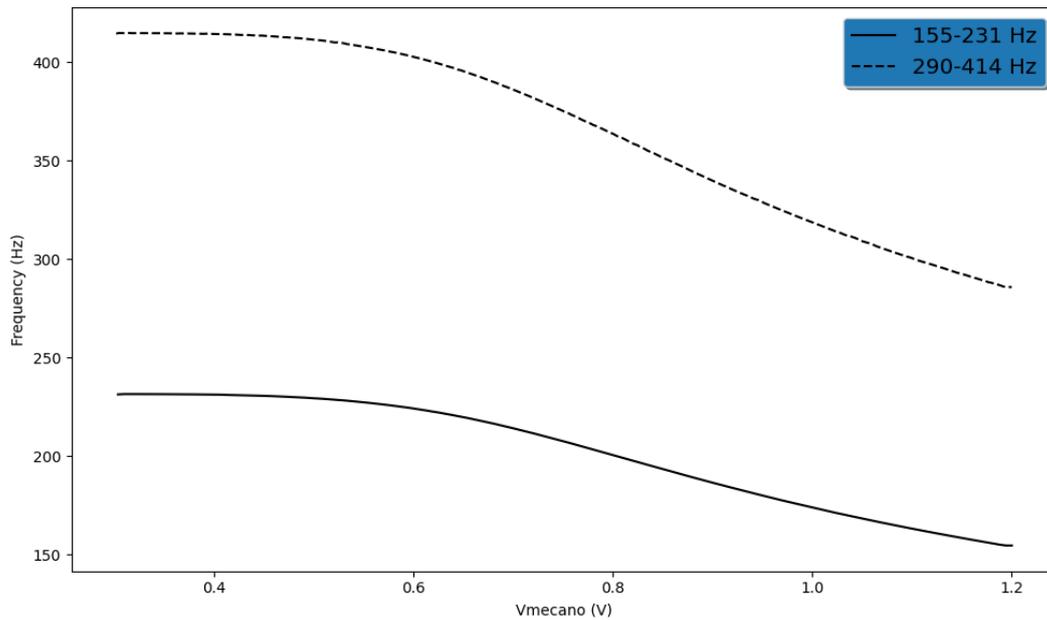
Fonte: Autor.

Figura 27 – Disparos na saída, V_{out} , para os *Intercepts* negativos, com intervalos de frequência de 54 à 88 Hz e 82 à 127 Hz



Fonte: Autor.

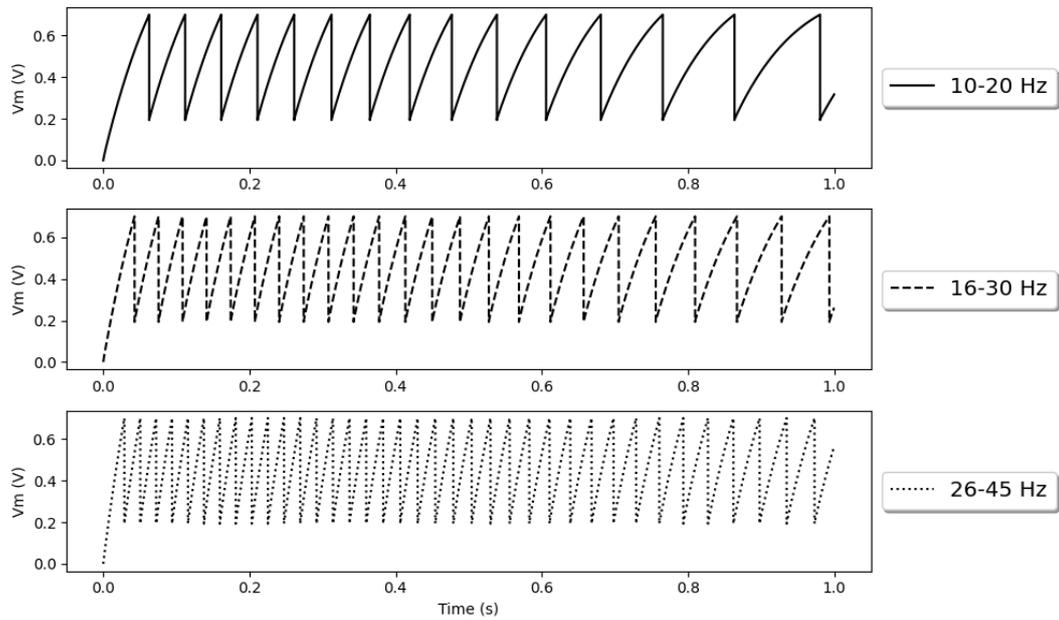
Figura 28 – Disparos na saída, V_{out} , para os *Intercepts* negativos, com intervalos de frequência de 155 á 231 Hz e 290 à 414 Hz



Fonte: Autor.

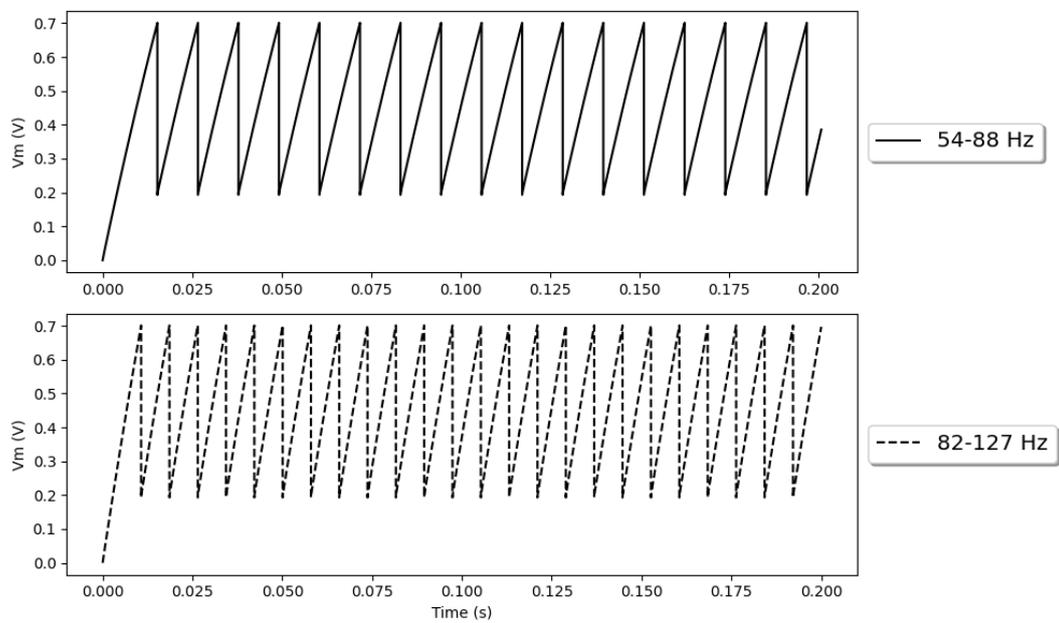
As figuras 29, 30 e 31 mostram a tensão da membrana no intervalo de um segundo. Para as frequências de disparo acima de 54 Hz foi feito um recorte de tempo para melhor visualização. Podemos visualizar a diminuição da frequência na tensão da membrana ao longo do tempo, causada pelo aumento da tensão V_{mecnao} .

Figura 29 – Tensão da membrana, V_m , para os *Intercepts* negativos, com intervalos de frequência de 10 Hz á 20 Hz, 16 à 30 Hz e 26 à 45 Hz



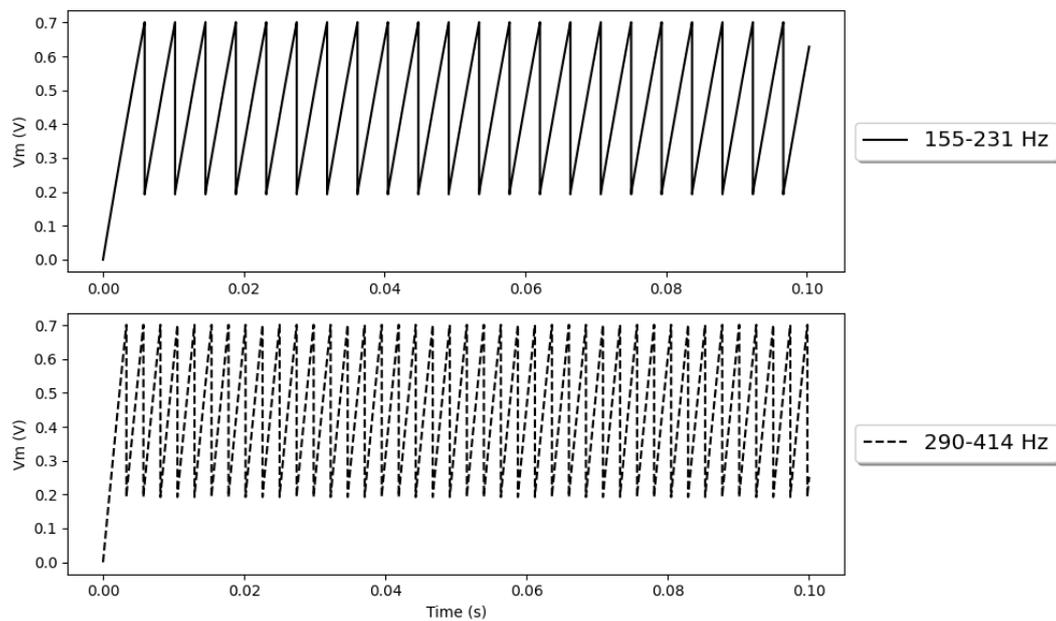
Fonte: Autor.

Figura 30 – Tensão da membrana, V_m , para os *Intercepts* negativos, com intervalos de frequência de 54 à 88 Hz e 82 à 127 Hz



Fonte: Autor.

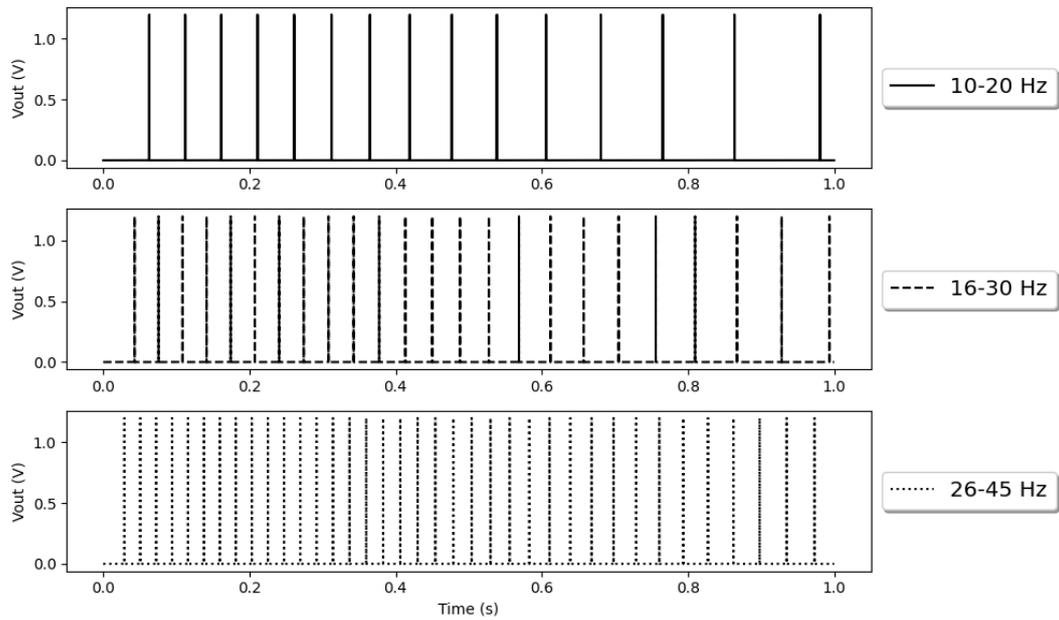
Figura 31 – Tensão da membrana, V_m , para os *Intercepts* negativos, com intervalos de frequência de 155 à 231 Hz e 290 à 414 Hz



Fonte: Autor.

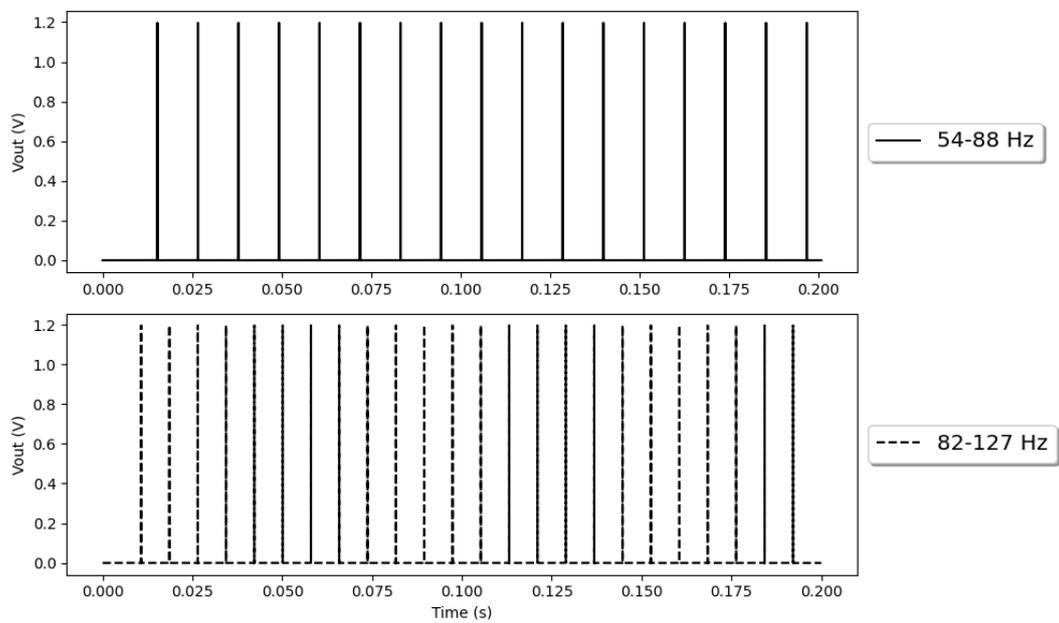
As figuras 32, 33 e 34 mostram os disparos na saída do neurônio no intervalo de um segundo. Para as frequências de disparo acima de 54 Hz foi feito um recorte de tempo para melhor visualização. Novamente podemos visualizar a diminuição da frequência de disparo da esquerda para a direita.

Figura 32 – Disparos na saída, V_{out} , para os *Intercepts* negativos, com intervalos de frequência de 10 Hz à 20 Hz, 16 à 30 Hz e 26 à 45 Hz



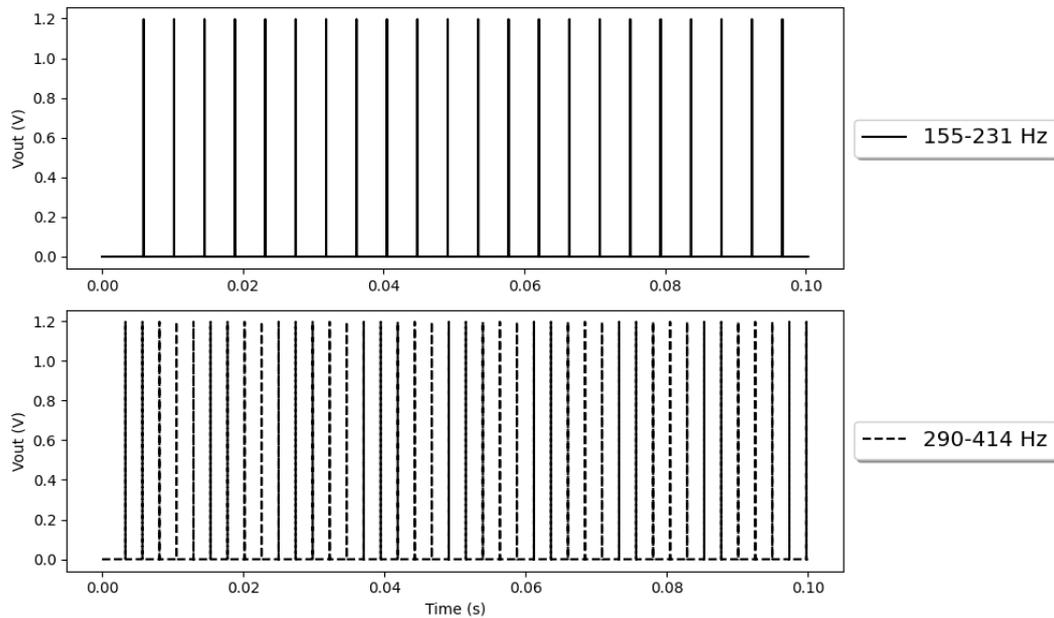
Fonte: Autor.

Figura 33 – Disparos na saída, V_{out} , para os *Intercepts* negativos, com intervalos de frequência de 54 à 88 Hz e 82 à 127 Hz



Fonte: Autor.

Figura 34 – Disparos na saída, V_{out} , para os *Intercepts* negativos, com intervalos de frequência de 155 à 231 Hz e 290 à 414 Hz



Fonte: Autor.

4.2 Variação de temperatura e processo

Nesta seção apresentaremos os resultados de simulação do comportamento do neurônio com relação às variações de temperatura e processos.

4.2.1 Temperatura

O teste feito para se obter o comportamento do circuito com relação à variação de temperatura foi aplicar a variação de temperatura no neurônio configurado para disparar até 60 Hz, frequência de disparo baixa em relação ao intervalo de 0 à 400 Hz, aplicando uma variação de temperatura de 5 °C, de 35 °C à 40 °C e considerando 37 °C como referência. Esse processo é repetido para frequências acima de 290 Hz, frequência de disparo alta em relação ao intervalo de 0 à 400 Hz. Para os *Intercepts* positivos, as tabelas 4, 5, 6 e 7 mostram os erros absolutos e relativos com relação à variação de temperatura. Em frequências baixas, o maior erro observado foi de 9.38 % em 40 °C. Para frequências de disparo altas o erro é menor e o maior erro observado é de 5.55 %, novamente em 40 °C. Com o aumento da temperatura há mais corrente sendo entregue

ao neurônio, porém também há maior fuga de corrente, que causa uma diminuição na frequência de disparo e faz os erros aumentarem.

Temperatura (°C)	Frequência (Hz)	Erro Absoluto	Erro Relativo (%)
35	39.34	2.05	5.49
37	37.29	-	-
40	34.03	3.26	8.74

Tabela 4 – Variação da frequência de disparo do neurônio com *intercepts* positivos em relação à variação de temperatura para uma taxa de disparo baixa

Temperatura (°C)	Frequência (Hz)	Erro Absoluto	Erro Relativo (%)
35	59.44	3.49	6.23
37	55.95	-	-
40	50.70	5.25	9.38

Tabela 5 – Variação da frequência de disparo do neurônio com *intercepts* positivos em relação à variação de temperatura para uma taxa de disparo baixa

Temperatura (°C)	Frequência (Hz)	Erro Absoluto	Erro Relativo (%)
35	316.409	7.809	2.53
37	308.6	-	-
40	296.85	11.75	3.80

Tabela 6 – Variação da frequência de disparo do neurônio com *intercepts* positivos em relação à variação de temperatura para uma taxa de disparo alta

Temperatura (°C)	Frequência (Hz)	Erro Absoluto	Erro Relativo(%)
35	424.45	15.71	3.84
37	408.74	-	-
40	386.04	22.7	5.55

Tabela 7 – Variação da frequência de disparo do neurônio com *intercepts* positivos em relação à variação de temperatura para uma taxa de disparo alta

Para os *Intercepts* negativos o mesmo comportamento é observado. As tabelas 8, 9, 10 e 11 mostram os erros absolutos e relativos com relação à variação de temperatura. Para baixas frequências de disparo o maior erro relativo observado foi de 9.61 % e em frequências altas de disparo o maior foi de 7.90%, ambos em 40 °C.

Temperatura (°C)	Frequência (Hz)	Erro Absoluto	Erro Relativo (%)
35	23.84	1.27	5.62
37	22.57	-	-
40	20.40	2.17	9.61

Tabela 8 – Variação da frequência de disparo do neurônio com *intercepts* negativos em relação à variação de temperatura para uma taxa de disparo baixa

Temperatura (°C)	Frequência (Hz)	Erro Absoluto	Erro Relativo (%)
35	41.44	1.99	5.04
37	39.45	-	-
40	36.33	3.12	7.90

Tabela 9 – Variação da frequência de disparo do neurônio com *intercepts* negativos em relação à variação de temperatura para uma taxa de disparo baixa

Temperatura (°C)	Frequência (Hz)	Erro Absoluto	Erro Relativo (%)
35	304.44	3.87	1.28
37	300.57	-	-
40	294.18	6.39	2.12

Tabela 10 – Variação da frequência de disparo do neurônio com *intercepts* negativos em relação à variação de temperatura para uma taxa de disparo alta

Temperatura (°C)	Frequência (Hz)	Erro Absoluto	Erro Relativo (%)
35	425.08	0.24	0.056
37	424.84	-	-
40	399.69	25.15	5.91

Tabela 11 – Variação da frequência de disparo do neurônio com *intercepts* negativos em relação à variação de temperatura para uma taxa de disparo alta

Se for levado em conta que a variação na feita na temperatura foi de apenas de 5 °C, de 35 °C à 40 °C, podemos dizer que o circuito é sensível à variação de temperatura por apresentar um erro de mais de 9 % nesta faixa.

4.2.2 Variação de processos

O teste feito para se obter o comportamento do circuito com relação à variação de processos foi alternar entre os corners tt, ss e ff. O corner tt, ou típico, é o padrão da tecnologia e os valores obtidos neste corner foram considerado o padrão para as

comparações feitas. O ss é um modelos de resposta lenta e por conta disso apresenta condução de corrente menor se comparado aos outros corners. Já o corner ff é um modelo de resposta rápida e isso significa maior condução de corrente se comparado aos outros corners. Novamente, o teste foi separado entre *Intercepts* positivos e negativo e também entre frequências de disparo mais baixas com relação ao intervalo de frequência de disparo, frequências abaixo de 60 Hz e para frequências de disparo mais altas, acima dos 290 Hz. Começando pelos *Intercepts* positivos, as tabelas 12, 13, 14 e 15 mostram os resultados obtidos dos erros absolutos e relativos com relação à variação de processos. O que pode ser observado é que para baixas frequências de disparo, os erros observados no corner ff são maiores que os observados no corner ss. Isso pode ser explicado pela característica do corner ff de permitir maior condução de corrente, que faz com que haja mais corrente vazando do neurônio e faz o capacitor carregar mais devagar. Isso também pode ser observado pela diferença na frequência de disparo.

Corners	Frequência (Hz)	Erro Absoluto	Erro Relativo(%)
ss	34.25	3.04	8.15
tt	37.29	-	-
ff	27.96	9.33	25.02

Tabela 12 – Variação da frequência de disparo do neurônio com *intercepts* positivos em relação à variação de processos para uma taxa de disparo baixa

Corners	Frequência (Hz)	Erro Absoluto	Erro Relativo(%)
ss	53.18	2.77	4.95
tt	55.95	-	-
ff	45.8	10.15	18.14

Tabela 13 – Variação da frequência de disparo do neurônio com *intercepts* positivos em relação à variação de processos para uma taxa de disparo baixa

Para frequências de disparo maior, o que se observa são valores de erros mais similares, com o pior caso sendo o corner ff, com um erro relativo de 22.76 %. Para frequências maiores, tipicamente a corrente que entra no circuito é maior o que minimiza o vazamento de corrente no corner ff.

Corners	Frequência (Hz)	Erro Absoluto	Erro Relativo(%)
ss	241.48	57.47	19.22
tt	298.95	-	-
ff	367.01	68.06	22.76

Tabela 14 – Variação da frequência de disparo do neurônio com *intercepts* positivos em relação à variação de processos para uma taxa de disparo alta

Corners	Frequência (Hz)	Erro Absoluto	Erro Relativo(%)
ss	358.6	50.16	12.27
tt	408.76	-	-
ff	457.38	48.62	11.89

Tabela 15 – Variação da frequência de disparo do neurônio com *intercepts* positivos em relação à variação de processos para uma taxa de disparo alta

Os *Intercepts* negativos no geral apresentaram erros maiores que os positivos, com o mais expressivo apresentando um erro relativo de 34.02%. Isso se deve pela maior variação no circuito auxiliar, gerador das curvas não lineares. Por outro lado, o menor erro observado na variação de corner foi obtida com os *Intercepts* negativos, especificamente com o corner ff em baixas frequências.

Corners	Frequência (Hz)	Erro Absoluto	Erro Relativo(%)
ss	22.82	4.46	16.34
tt	27.28	-	-
ff	20.83	6.45	23.64

Tabela 16 – Variação da frequência de disparo do neurônio com *intercepts* negativos em relação à variação de processos para uma taxa de disparo baixa

Corners	Frequência (Hz)	Erro Absoluto	Erro Relativo(%)
ss	39.53	6.44	14.00
tt	45.97	-	-
ff	44.07	1.9	4.13

Tabela 17 – Variação da frequência de disparo do neurônio com *intercepts* negativos em relação à variação de processos para uma taxa de disparo baixa

Corners	Frequência (Hz)	Erro Absoluto	Erro Relativo(%)
ss	219.94	80.63	26.82
tt	300.57	-	-
ff	402.84	102.27	34.02

Tabela 18 – Variação da frequência de disparo do neurônio com *intercepts* negativos em relação à variação de processos para uma taxa de disparo alta

Corners	Frequência (Hz)	Erro Absoluto	Erro Relativo(%)
ss	331.26	83.58	20.14
tt	414.84	-	-
ff	515.05	100.21	24.15

Tabela 19 – Variação da frequência de disparo do neurônio com *intercepts* negativos em relação à variação de processos para uma taxa de disparo alta

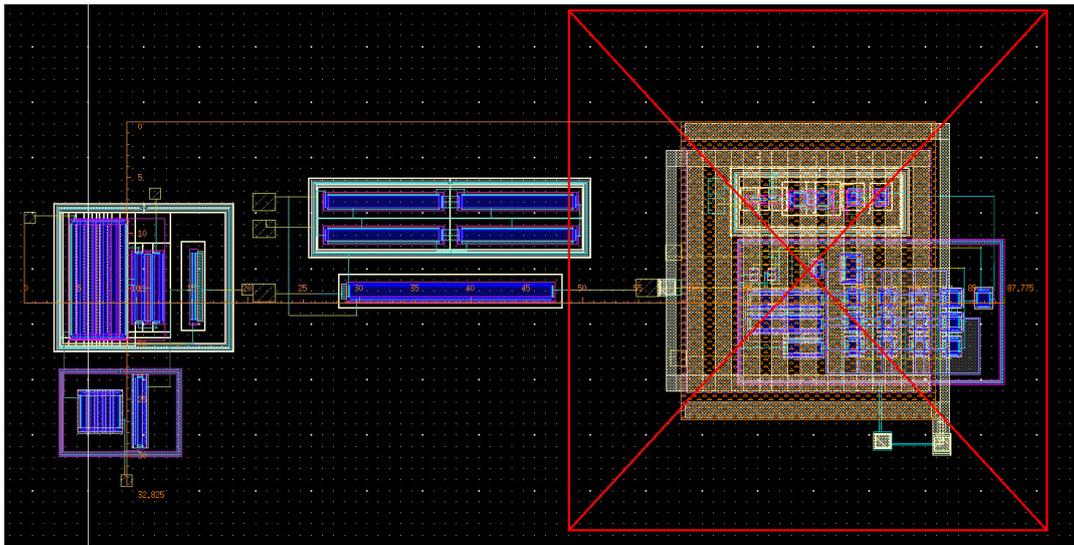
4.2.3 Consumo de potência e energia por disparo

O consumo de potência de todo o circuito foi obtido em frequências baixas, 25 Hz, pois foram os casos que apresentaram maiores consumos de potência. Para os *Intercepts* positivos o consumo médio de potência ficou em $5.375 \mu\text{A}$ e para os *Intercepts* negativos o consumo médio observado foi de $5.363 \mu\text{A}$. A energia por disparo ficou em torno de 214 nJ, valor que pode ser considerado extremamente alto se comparado aos trabalhos (CRUZ-ALBRECHT; YUNG; SRINIVASA, 2012), (INDIVERI; CHICCA; DOUGLAS, 2006), (INDIVERI, 2003) e (HAZAN; TSUR, 2021). A principal causa desse consumo elevado de potência e energia está relacionada ao comparador Schmitt Trigger. Para reduzir os vazamentos de corrente do circuito e alcançar frequências de disparo mais baixas, foi necessário recorrer ao uso de transistores de óxido espesso. Esses transistores demandam uma maior corrente para mudar o estado do comparador, o que resulta no aumento do consumo de energia do neurônio.

4.2.4 Leiaute

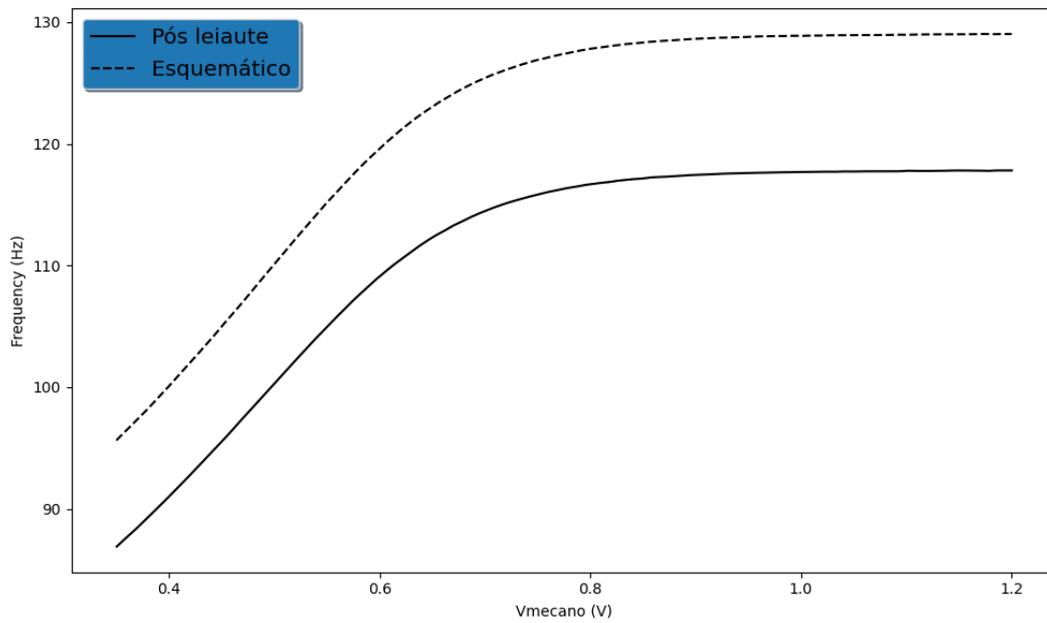
Na figura 35 é mostrado o leiaute do neurônio, para os *Intercepts* positivos. As dimensões do circuito são $87.775 \times 32.825 \mu\text{m}$, o que resulta em uma área de $2881 \mu\text{m}^2$. Após aplicar as verificações de *Design Rule Check* e *Layout versus Schematic* foi possível extrair os parasitas RC do circuito. As figuras 36 e 37 mostram os resultados da simulação utilizando apenas a vista esquemático e a vista extraída, considerando os parasitas do circuito.

Figura 35 – Leiaute do neurônio com seu respectivo circuito auxiliar



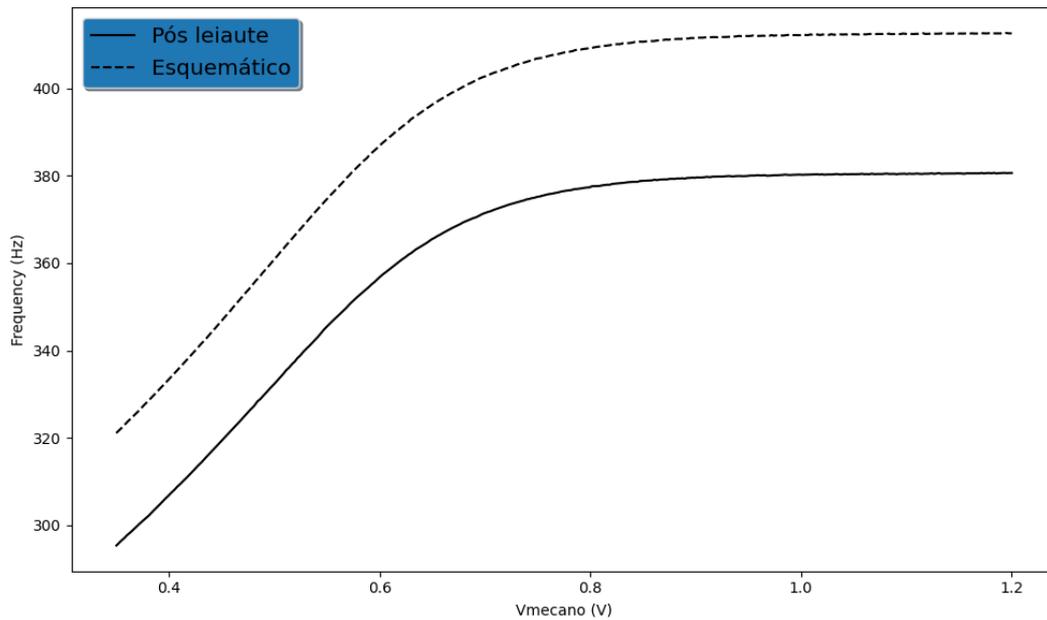
Fonte: Autor.

Figura 36 – Resultado das simulações dos *Intercepts* com a vista nível esquemático e extraída pós leiaute 1



Fonte: Autor.

Figura 37 – Resultado das simulações dos *Intercepts* com a vista nível esquemático e extraída pós leiaute 2



Fonte: Autor.

Como pode ser observado nas tabelas 20, 21, 22 e 23, a frequência do neurônio com a vista extraída em todos os casos ficou abaixo do circuito com a vista nível esquemático e isso pode ser explicado pelo fato dos componentes RC parasitas adicionado no circuito. Mas o erro relativo ficou entre 7% a 9%, valor aceitável entre as vistas nível esquemático e extraída.

Vista	Frequência (Hz)	Erro Absoluto	Erro Relativo(%)
Esquemático	95.62	-	-
Extraída	86.86	8.76	9.16

Tabela 20 – Erros absoluto e relativo entre a vista nível esquemático e extraída pós leiaute com relação as curvas da figura 36.

Vista	Frequência (Hz)	Erro Absoluto	Erro Relativo(%)
Esquemático	117.78	-	-
Extraída	128.96	11.18	8.66

Tabela 21 – Erros absoluto e relativo entre a vista nível esquemático e extraída pós leiaute com relação as curvas da figura 36.

Vista	Frequência (Hz)	Erro Absoluto	Erro Relativo(%)
Esquemático	321.09	-	-
Extraída	295.31	25.78	8.02

Tabela 22 – Erros absoluto e relativo entre a vista nível esquemático e extraída pós leiaute com relação as curvas da figura 37.

Vista	Frequência (Hz)	Erro Absoluto	Erro Relativo(%)
Esquemático	412.45	-	-
Extraída	380.37	32.08	7.77

Tabela 23 – Erros absoluto e relativo entre a vista nível esquemático e extraída pós leiaute com relação as curvas da figura 37.

5 Conclusão

Os resultados acima mostram que é possível obter o comportamento e trabalhar na faixa de frequência dos neurônios simulados no NENGO. Com o suporte do circuito auxiliar, tanto os *Intercepts* positivos quanto os negativos foram alcançados.

Em relação ao desempenho aplicando-se variações de temperatura e processos, o circuito mostrou-se sensível a ambas as variações. Com apenas uma variação de 5 °C, o circuito apresentou um erro relativo de 9.61% no pior caso, e com a variação de corners, o erro chegou a 34.02%. No que diz respeito à variação de temperatura, neste circuito, o aumento da temperatura faz o vazamento de corrente aumentar e, conseqüentemente, gera erros maiores. Já em relação à variação de corners, os corners ff apresentam uma maior condução de corrente, o que, em frequências menores, até 60 Hz, gera mais fuga de corrente e faz a frequência de disparo diminuir. Isso ocorre porque, nessa faixa de frequência de disparo, a corrente de trabalho do neurônio está na casa dos pA, e um pequeno vazamento é suficiente para aumentar o erro significativamente. Em frequências maiores, acima de 300 Hz, ocorre o inverso: mais corrente entra no neurônio, resultando em uma frequência de disparo maior.

Infelizmente, não foi possível obter a curva de *Intercepts* em uma única configuração, isto é, iniciar a operação em frequências baixas e alcançar 400 Hz sem modificar nenhum outro parâmetro. Foi necessário dividir a faixa de frequência de operação em intervalos e, para transitar para o próximo intervalo, foi necessário ajustar a relação de aspecto dos transistores que fornecem corrente ao circuito. Isso implica que, para abranger toda a faixa de frequência prevista, é necessário mais de um neurônio, com mudanças na relação de aspecto dos transistores de entrada. Ao analisar trabalhos similares, como o de (INDIVERI; CHICCA; DOUGLAS, 2006), é perceptível que há dificuldades em transitar diretamente de frequências baixas para frequências mais altas. Estudos como os de (HAZAN; TSUR, 2021) e (INDIVERI, 2003) propõem uma possível solução, que envolve ajustar periodicamente a inclinação da curva para reproduzir o comportamento desejado.

Com relação ao consumo de potência e energia por disparo, foi observado um aumento significativo no consumo de potência em comparação com outros trabalhos, como o apresentado por (CRUZ-ALBRECHT; YUNG; SRINIVASA, 2012), que registrou um consumo na ordem de pW. Neste trabalho, o consumo médio de potência foi registrado em 5.363 uW. Esse aumento no consumo é principalmente atribuído ao Schmitt Trigger,

especialmente devido ao uso de transistores de óxido espesso, os quais foram empregados para reduzir o vazamento de corrente em baixas frequências. Como consequência, a energia por disparo atingiu seu valor máximo de 214 nJ. Portanto, embora o uso de transistores de óxido espesso tenha resolvido um problema, ele introduziu outro de importância similar. Assim, para trabalhos futuros, torna-se necessário implementar e testar outras topologias de comparadores.

Referências Bibliográficas

- BAKER, R. J. *CMOS: Circuit Design, Layout, and Simulation (IEEE Press Series on Microelectronic Systems)*. [S.l.]: Wiley-IEEE Press, 2019. 31
- BHATTACHARYYA, A. B. *Compact MOSFET Models for VLSI Design*. [S.l.]: John Wiley Sons, 2009. 17
- CRUZ-ALBRECHT, J. M.; YUNG, M. W.; SRINIVASA, N. Energy-efficient neuron, synapse and stdp integrated circuits. *IEEE Transactions on Biomedical Circuits and Systems*, v. 6, n. 3, p. 246–256, 2012. 54, 58
- ELIASMITH, C. H. A. C. *Neural Engineering: Computation, Representation, And Dynamics In Neurobiological Systems (Computational Neuroscience series)*. [S.l.]: Bradford Books, 2004. 24, 26, 27
- HAZAN, A.; TSUR, E. E. Neuromorphic analog implementation of neural engineering framework-inspired spiking neuron for high-dimensional representation. *Frontiers in Neuroscience*, v. 15, 2021. ISSN 1662-453X. Disponível em: <<https://www.frontiersin.org/articles/10.3389/fnins.2021.627221>>. 15, 54, 58
- INDIVERI, G. A low-power adaptive integrate-and-fire neuron circuit. In: *Proceedings of the 2003 International Symposium on Circuits and Systems, 2003. ISCAS '03*. [S.l.: s.n.], 2003. v. 4, p. IV–IV. 54, 58
- INDIVERI, G.; CHICCA, E.; DOUGLAS, R. A vlsi array of low-power spiking neurons and bistable synapses with spike-timing dependent plasticity. *IEEE Transactions on Neural Networks*, v. 17, n. 1, p. 211–221, 2006. 54, 58
- INTEL. *Loihi 2: A New Generation of Neuromorphic Computing*. 2023. Disponível em: <<https://www.intel.com/content/www/us/en/research/neuromorphic-computing.html>>. 15
- JONE, F. *Aplicação de redes neurais pulsadas no processamento de sinais de mecanorreceptores táteis eletrônicos*. 2023. 14, 16
- KANDEL JAMES H. SCHWARTZ, T. M. J. E. R. [S.l.: s.n.]. 14
- LEÃO, R. M. *Os Canais Iônicos*. 2023. Disponível em: <https://edisciplinas.usp.br/pluginfile.php/270553/mod_resource/content/2/aula%20canais%20ionicos.pdf>. 23
- NENGO. [S.l.], 2023. Disponível em: <<https://www.nengo.ai/documentation/>>. 15
- PURVES GEORGE J. AUGUSTINE, D. F. W. C. H. A.-S. L. J. O. M. S. M. W. D. *Neuroscience*. [S.l.]: Sinauer Associates Inc, 2004. 21, 23

RASPBERRY. [S.l.], 2023. Disponível em: <<https://datasheets.raspberrypi.com/rpi4/raspberry-pi-4-datasheet.pdf>>. 16

SCHNEIDER, C. G.-M. M. C. *CMOS Analog Design Using All-Region MOSFET Modeling*. [S.l.]: Cambridge University Press, 2010. 17, 19

SILVERTHORN, D. U. *Fisiologia Humana: Uma Abordagem Integrada*. [S.l.]: Artmed, 2017. 20, 22, 24

YANG, Z. et al. Analog circuit implementation of lif and stdp models for spiking neural networks. In: *Proceedings of the 2020 on Great Lakes Symposium on VLSI*. New York, NY, USA: Association for Computing Machinery, 2020. (GLSVLSI '20), p. 469–474. ISBN 9781450379441. Disponível em: <<https://doi.org/10.1145/3386263.3406940>>. 26, 28, 29, 30, 32