

Comparação da Acurácia na Classificação de Diferentes Texturas Entre Modelos Neuromórficos de Izhikevich

Vinicius de Carvalho Zanini
Faculdade de Engenharia Elétrica
Universidade Federal de Uberlândia
Uberlândia, Brasil
ORCID: 0000-0003-3376-9636

Ana Clara Pereira Resende da Costa
Faculdade de Engenharia Elétrica
Universidade Federal de Uberlândia
Uberlândia, Brasil
ORCID: 0000-0002-5533-8880

Sergio Ricardo de Jesus de Oliveira
Faculdade de Engenharia Elétrica
Universidade Federal de Uberlândia
Uberlândia, Brasil
ORCID: 0000-0003-2294-2018

Ailton Luis Dias Siqueira Junior
Instituto Federal de Educação Ciência
e Tecnologia do Triângulo Mineiro
Ituiutaba, Brasil
ORCID: 0000-0002-8944-5625

Alcimar Barbosa Soares
Faculdade de Engenharia Elétrica
Universidade Federal de Uberlândia
Uberlândia, Brasil
ORCID: 0000-0003-1100-3533

Abstract— *For the last years, the study of the neuromorphic touch got the spotlight because of its multiple's applications in robotics and rehabilitation such as texture classification. In this paper it is used a neuromorphic model for the classification of the data from 8 different textures to see which one of the neurons modeled by Izhikevich presents most accuracy as a second layer neuron. After the tests, it was showed that from the 8 different neuron models presented, the one with the best accuracy was the low-threshold spiking model with 81,25%.*

Keywords — *tactile, neuromorphic, robotic, classification.*

I. INTRODUÇÃO

Recentemente dentro do campo da engenharia neuromórfica uma linha que ganhou destaque foi a do tato neuromórfico devido a suas diversas aplicações tanto no campo da robótica, a partir de detecção de escorregamento [1], classificação de texturas [2], rugosidade [3] e orientação de borda [4], quanto no campo da reabilitação com enfoque na restauração da retroalimentação tátil em amputados [5]. O tato neuromórfico busca combinar a capacidade biológica do processamento somatossensorial e arquiteturas neurais objetivando atingir a eficiência computacional biológica, a partir de modelos bioinspirados em neurônios biológicos [4][6].

Um dos modelos neurais mais utilizados no campo do tato neuromórfico é o Modelo de Izhikevich [7] que permite simular o comportamento de disparo de diferentes neurônios biológicos, incluído de mecanorreceptores presente na pele glabra [2]. Esses mecanorreceptores, também conhecidos como aferentes primários, são responsáveis por codificar as diferentes informações táteis, existindo dois principais tipos, os adaptação lenta (AL), sensíveis estímulos estáticos como indentação de pele, e os de adaptação rápida (AR), sensíveis a estímulos transientes e vibrações [8].

As informações desses aferentes são combinadas por aferentes secundários e terciários e são interpretadas no córtex somatossensorial [8]. Ainda é um desafio reproduzir a capacidade biológica de combinar e interpretar uma alta densidade de aferentes primários. Sendo assim, o objetivo desse trabalho é avaliar qual o melhor modelo neural proposto por Izhikevich em (2003) para combinar informações táteis advindas dos aferentes primários artificiais

possibilitando uma segregação e classificação de texturas naturalísticas.

II. MATERIAIS E MÉTODOS

A. Base de Dados

Para o desenvolvimento do trabalho foi utilizada uma base de dados desenvolvida por Gupta [2] que contém coletas de palpação ativa de 8 texturas naturalísticas em diferentes velocidades realizadas por um braço robótico equipado com um sensor tátil de 16 taxels piezoresistivos. As 8 texturas são classificadas como tapete têxtil (TT), papel ondulado (PO), esponja (ES), isopor (IS), piso de borracha (PB), piso cinza (PC), piso colorido (PCO) e piso liso (PL), os dados utilizados foram amostrados em uma frequência de 1KHz, coletados em uma velocidade constante de 10 mm/s e com uma força normal de 1 N. Nessa condição de coleta cada textura possui 20 amostras.

B. Pré-Processamento

Esses dados foram pré-processados utilizando um filtro passa-baixa *butterworth* de 4ª ordem com uma frequência de corte de 30 Hz. Após isso os sinais foram normalizados em relação as amostras de maior (v_{max}) e menor (v_{min}) amplitude conforme descrito em (1):

$$n_i = \frac{x_i - v_{min}}{v_{max} - v_{min}} \quad (1)$$

Em que i é o vetor de dados digitais, n_i é o valor normalizado de um taxel em i e x_i é a amostra na posição i . Por fim, foi realizado a segmentação dos dados em 6 segundos de palpação ativa para cada textura.

C. Rede Neural Neuromórfica

A rede neural neuromórfica utilizada nesse artigo é dividida em duas camadas distintas como mostrado na Fig. 1:

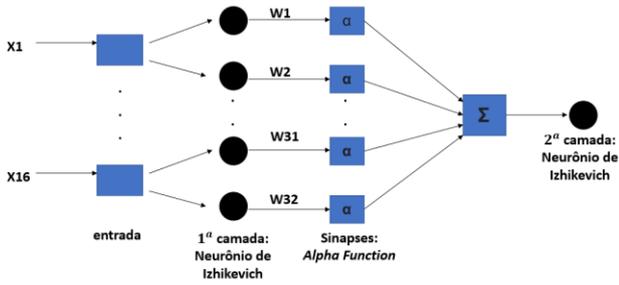


Fig. 1. Modelo da rede neural neuromórfica utilizada

Na primeira camada temos a entrada dos sinais coletados por cada um dos 16 taxels indo como corrente de entrada para 2 modelos de aferentes primários distintos modelados utilizando o método de Izhikevich [7]. O primeiro simula um mecanorreceptor AR, para isso foi utilizado um ganho de 3000 na corrente de entrada (sinal de força de 16 canais), nota-se que como esse mecanorreceptor é sensível apenas a estímulos transientes, a corrente de entrada foi derivada, enquanto o segundo simula um mecanorreceptor de adaptação lenta AL com o ganho igual a 20 na corrente de entrada, resultando em um total de 32 sinais que são binarizados, simulando potenciais de ação (*spikes*) e enviados para a segunda camada, como já visto em [9].

Para converter os *spikes* em uma corrente sináptica para a entrada da segunda camada foi utilizado o modelo *alpha function* [10]. Sendo assim, para cada neurônio da primeira camada foi modelada uma corrente sináptica, e a soma das 32 correntes sinápticas foram utilizadas como corrente de entrada do neurônio de saída que foi modelado com base nos 8 diferentes neurônios propostos por Izhikevich. A saída desse neurônio também será na forma binarizada, ou seja, neuromórfica, ela será utilizada para avaliar qual modelo dos diferentes neurônios é capaz de melhor combinar as entradas táteis e possibilitar a segregação e classificação das 8 diferentes classes de texturas.

1) *Modelo de Izhikevich*: O modelo de Izhikevich é composto por um sistema de equações diferenciais de segunda ordem que conseguem reproduzir, de maneira computacionalmente simples, diferentes padrões de disparos de neurônios biológicos [7]. Onde (2) representa o potencial de membrana do neurônio e (3) a variável de recuperação da membrana:

$$v' = 0.04v^2 + 5v + 140 - u + I \quad (2)$$

$$u' = a(bv - u) \quad (3)$$

E (4) descreve o restabelecimento do potencial de membrana e da variável de recuperação pós-*spike*:

$$\text{Se } v \leq 30 \text{ mV então } \begin{cases} v \leftarrow c \\ u \leftarrow u + d \end{cases} \quad (4)$$

Onde temos v como o potencial de membrana do neurônio, u a variável de recuperação, I a corrente sináptica (corrente de entrada), a é o parâmetro que descreve a escala de tempo de u , b o parâmetro de sensibilidade de u , c o resete pós-*spike* de v , e d o resete pós-*spike* de u .

Os diferentes padrões de disparos modelados por Izhikevich, *regular spiking* (RS) (utilizado no AL), *intrinsically bursting* (IB), *chattering* (CH), *fast spiking* (FS) (utilizado para o AR), *low-threshold spiking* (LTS), *thalamo-*

cortical (TC), *resonator* (RZ), e o neurônio típico (TP) são criados pela variação dos valores de a, b, c, d como podemos ver na Tab I:

TABELA I. VALORES DAS VARIÁVEIS SUGERIDAS POR IZHIKEVICH PARA O DESENVOLVIMENTO DE CADA MODELO DE NEURÔNIO

Variáveis	Modelos de Neurônios							
	TP	RS	IB	CH	FS	LTS	TC	RZ
a	0.02	0.02	0.02	0.02	0.1	0.02	0.02	0.1
b	0.2	0.2	0.2	0.2	0.2	0.25	0.25	0.26
c	-65	-65	-55	-50	-65	-65	-65	-65
d	2	8	4	2	2	2	0.05	2

2) *Alpha Function*: A *alpha function* é uma função utilizada para modelar correntes sinápticas dos dados entrados [10] como demonstrado em (5):

$$g_{syn}(t) = \bar{g}_{syn} \frac{t-t_0}{\tau} e^{1-(t-t_0)/\tau} \quad (5)$$

Onde g_{syn} representa a condutância sináptica no tempo t sendo $g_{syn} = 0$ para $t < t_0$, \bar{g}_{syn} é o peso sináptico que determina o valor de pico da sinapse simulada, sendo para essa equação 8, $t_0 = 10 \text{ ms}$ representando na equação o instante de tempo em que ocorre o *spike*, e τ a constante de tempo em ms valendo 1,7.

D. Validação Computacional

Gerado a saída dos *spikes* de cada modelo de neurônio, se faz necessário validar qual o melhor modelo para otimizar a separabilidade dos dados. Para isso foi extraída duas características do vetor de disparos de cada neurônio. A primeira é a taxa média de *spikes* (TMS) apresentada em (6), que descreve a taxa global de disparos do neurônio modelado

$$TMS = \sum_{i=1}^n disp_i / T \quad (6)$$

Onde $disp$ é o vetor de disparos e T é o tempo de duração desse vetor em segundos, aqui igual a 6 segundos. A segunda característica extraída é o coeficiente de variação do intervalo *inter-spike* (CV-ISI) dos disparos, descrito por (7), que é uma estimativa da variação do tempo entre os disparos:

$$CV - ISI = \frac{\sigma_{ISI}}{\mu_{ISI}} \quad (7)$$

Em que σ_{ISI} é o desvio padrão e μ_{ISI} é a média dos intervalos entre disparos do vetor $disp$. Por fim essas características foram utilizadas para treinamento por uma máquina de vetor de suporte, do inglês *support vector machine* (SVM) de *kernel* linear, utilizando a validação *leave one out*, onde foram analisados o SVM e o CV-ISI para ser possível identificar a diferenciabilidade entre as texturas pelo neurônio modelado

III. ANÁLISE

Para visualização das diferentes características dos modelos neuronais implementados e a separabilidade dos dados, a Tab. II apresenta os valores médios do CV-ISI de cada textura para cada um dos diferentes modelos de neurônios, a Tab. III possui a mesma função, porém apresentando para o TMS e a Fig. 2 a tabela de confusão da classificação do SVM para cada modelo de neurônio de segunda camada.

TABELA II. CV-ISI MÉDIO DE CADA TEXTURA PARA CADA MODELO DE NEURÔNIO

Textura	Modelos de Neurônios							
	TP	RS	IB	CH	FS	LTS	TC	RZ
TT	0,64 ± 0,03	0,45 ± 0,03	0,69 ± 0,046	1,20 ± 0,03	0,54 ± 0,02	0,57 ± 0,03	0,75 ± 0,02	0,65 ± 0,02
PO	0,73 ± 0,03	0,56 ± 0,02	0,82 ± 0,02	1,10 ± 0,03	0,62 ± 0,01	0,71 ± 0,01	0,59 ± 0,015	0,54 ± 0,01
ES	0,69 ± 0,03	0,50 ± 0,04	0,77 ± 0,04	1,12 ± 0,03	0,61 ± 0,02	0,69 ± 0,03	0,62 ± 0,02	0,53 ± 0,01
IS	0,69 ± 0,03	0,50 ± 0,03	0,77 ± 0,04	1,11 ± 0,03	0,62 ± 0,02	0,70 ± 0,03	0,62 ± 0,02	0,53 ± 0,02
PB	0,71 ± 0,02	0,50 ± 0,03	0,78 ± 0,03	1,10 ± 0,03	0,63 ± 0,02	0,71 ± 0,02	0,62 ± 0,02	0,54 ± 0,01
PC	0,84 ± 0,04	0,60 ± 0,03	0,88 ± 0,03	1,24 ± 0,04	0,73 ± 0,02	0,77 ± 0,02	0,72 ± 0,03	0,64 ± 0,03
PCO	0,74 ± 0,06	0,51 ± 0,04	0,78 ± 0,06	1,27 ± 0,05	0,64 ± 0,07	0,68 ± 0,06	0,86 ± 0,08	0,75 ± 0,07
PL	0,67 ± 0,02	0,50 ± 0,03	0,77 ± 0,02	1,07 ± 0,02	0,59 ± 0,02	0,65 ± 0,02	0,58 ± 0,02	0,52 ± 0,02

TABELA III. TMS MÉDIO DE CADA TEXTURA PARA CADA MODELO DE NEURÔNIO

Textura	Modelos de Neurônios							
	TP	RS	IB	CH	FS	LTS	TC	RZ
TT	25,42 ± 1,66	14,94 ± 0,87	21,43 ± 1,48	37,97 ± 2,30	42,35 ± 2,35	40,68 ± 1,54	69,92 ± 4,21	61,93 ± 3,61
PO	75,65 ± 3,22	36,42 ± 1,31	58,45 ± 2,44	97,50 ± 3,98	119,32 ± 5,90	88,85 ± 3,27	169,30 ± 6,51	145,90 ± 5,40
ES	53,57 ± 3,52	26,99 ± 1,84	42,31 ± 2,82	70,79 ± 4,32	80,98 ± 5,52	66,34 ± 3,71	126,49 ± 6,46	109,65 ± 5,44
IS	54,77 ± 2,63	27,56 ± 1,18	43,22 ± 2,13	70,06 ± 3,31	82,76 ± 4,53	67,77 ± 3,02	128,66 ± 5,28	111,66 ± 4,23
PB	61,47 ± 4,41	30,41 ± 1,85	48,03 ± 3,18	80,69 ± 5,06	94,85 ± 7,90	74,70 ± 4,69	142,43 ± 9,11	123,04 ± 7,81
PC	59,04 ± 1,97	28,83 ± 0,89	45,92 ± 1,50	77,72 ± 2,41	92,36 ± 3,97	72,22 ± 2,26	138,80 ± 4,63	119,43 ± 3,94
PCO	29,57 ± 1,45	16,69 ± 0,59	24,72 ± 1,09	43,19 ± 1,83	46,47 ± 2,02	43,47 ± 1,26	79,07 ± 2,97	68,45 ± 2,52
PL	63,15 ± 2,65	31,19 ± 1,23	49,22 ± 2,01	81,85 ± 3,27	98,63 ± 4,80	76,78 ± 2,65	146,32 ± 5,44	126,45 ± 4,71

A. Regular Spiking

Para o RS é possível verificar que o TMS variou entre $14,94 \pm 0,87$ e $36,42 \pm 1,31$ e o CV-ISI entre $0,45 \pm 0,03$ e $0,60 \pm 0,03$. Apresenta menor acurácia de classificação para as texturas ES, IS, PL e PB, que apresentam características semelhantes nas tabelas, nos dando uma acurácia média de 73,75%.

B. Intrinsically Bursting

A variação da TMS do neurônio IB observada na Tab. III foi entre $21,43 \pm 1,48$ e $58,45 \pm 2,44$ e para o CV-ISI, na Tab. II, entre $0,69 \pm 0,05$ e $0,88 \pm 0,03$, verifica-se também, pela matriz de confusão que se teve uma dificuldade de distinguir a textura IS da ES e da PB, a PB também sofre dificuldades de identificação com a PL, ficando a textura com uma acurácia de apenas 45%. Porém o neurônio como um todo mostra uma acurácia média de 79,37% sendo até maior que a anterior.

C. Chattering

Encontra-se, no CH, um CV-ISI bem maior que o dos modelos anteriores na Tab. II, com um mínimo de $1,07 \pm 0,02$ e máximo de $1,27 \pm 0,05$ e no TMS varia entre $37,97 \pm 2,230$ e $98,63 \pm 4,80$. Também é possível ver na matriz de confusão na Fig. 2 que a dificuldade de distinção se manteve na textura IS e ES, e do PL e PB, dando uma acurácia média de 80,62%.

D. Fast Spiking

Por sua vez, o FS mostra na Tab. III uma variação maior entre o TMS de cada textura, com maior proximidade entre IS e ES, no CV-ISI é apresentado uma variação entre $0,54 \pm 0,02$ e $0,71 \pm 0,01$ e após o treinamento apresentou uma acurácia média de 80,62%

E. Low-Threshold Spiking

O LTS apresenta valores parecidos com o FS, seu CV-ISI varia entre $0,57 \pm 0,03$ e $0,77 \pm 0,03$, TMS de $40,68 \pm 1,54$ até $76,78 \pm 2,65$ apresentando a maior acurácia média com 81,25%

F. Thalamo-Cortical

Com o TC, a matriz de confusão na Fig. 2 volta a apresentar maiores problemas de identificação entre as texturas IS com ES e o IS com o PB e também com o PL, dando uma acurácia média de 78,12%. Essa dificuldade de identificação poderia ser esperada ao comparar a proximidade de seus CV-ISI e TMS na Tab. II e III.

G. Resonator

Verificando a Tab. II e III do RZ, nota-se valores bem próximos para as texturas ES, IS e PB, o que se reflete ao observar na Fig. 2 uma maior dificuldade de separabilidade entre essas classes. Seu CV-ISI varia entre $0,52 \pm 0,02$ e $0,75 \pm 0,07$ e o TMS de $61,93 \pm 3,61$ até $145,90 \pm 5,40$.

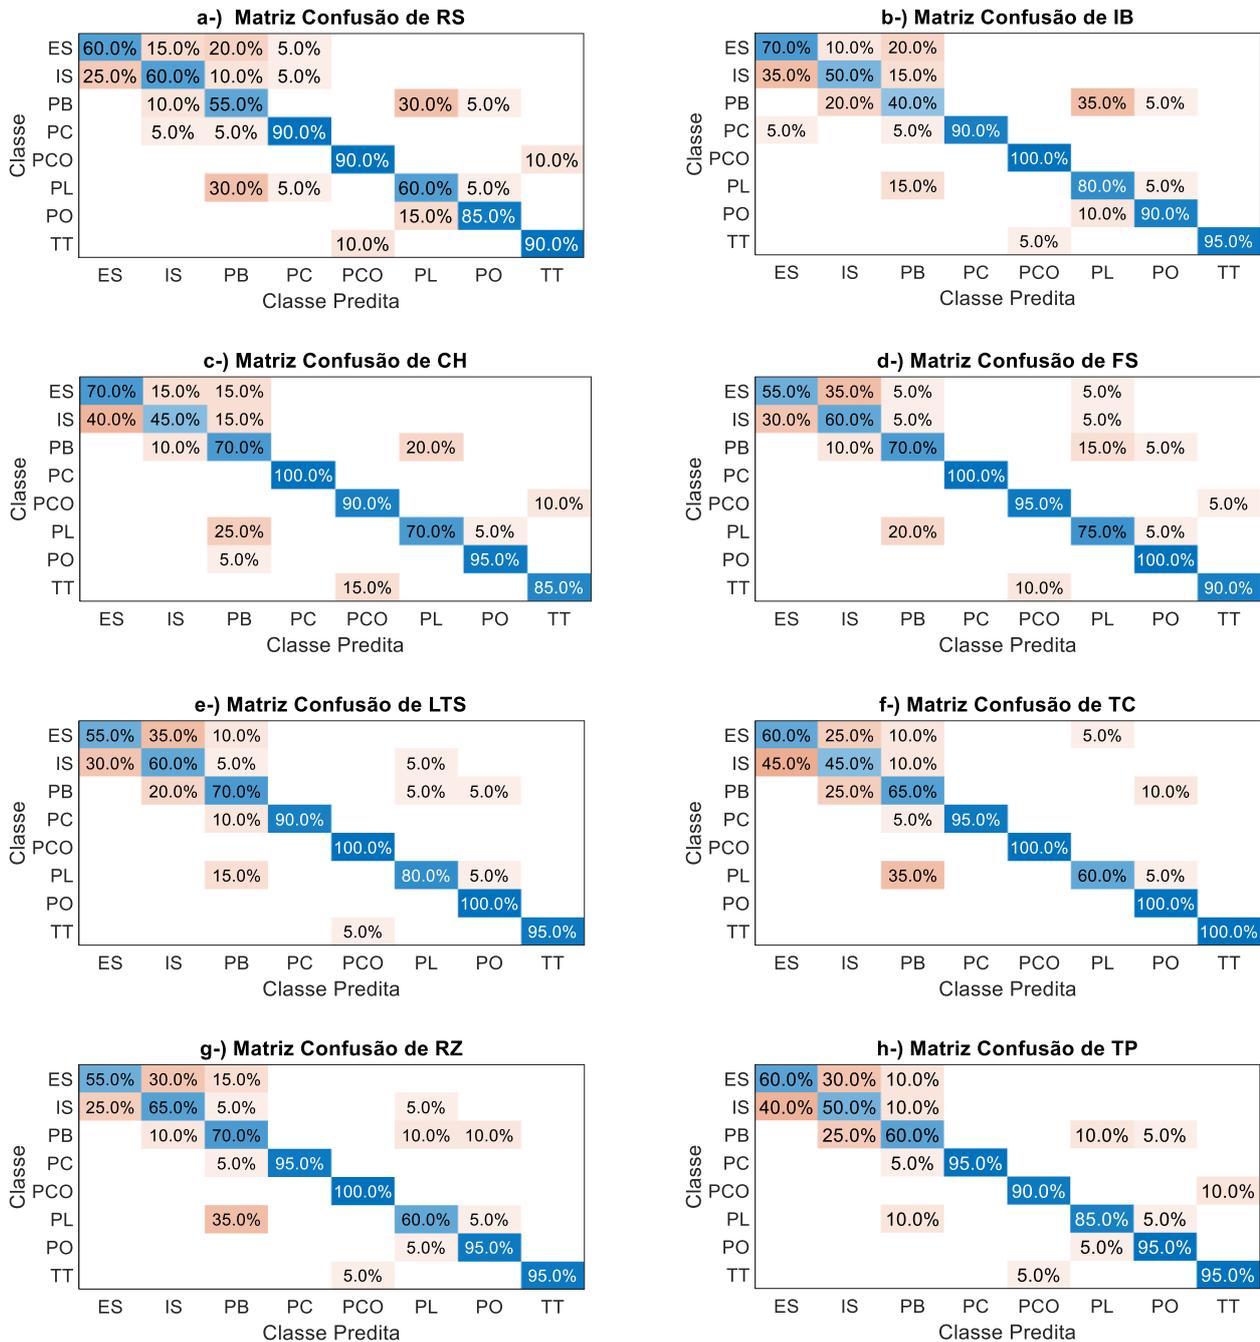


Fig. 2 Matrizes de confusão mostrando a porcentagem de erros e acertos de classificação das 8 diferentes texturas para os modelos de neurônios a-) regular spiking b-) intrinsically bursting c-) chattering d-) fast spiking e-) low-threshold spiking e-) thalamo-cortical g-) resonator f-) típico, sendo a coluna vertical as 8 classes de texturas e a coluna horizontal a classe predita.

H. Típico

Por fim, foi feito as medidas para os parâmetros TP que apresenta o CV-ISI entre $0,64 \pm 0,03$ e $0,84 \pm 0,04$, com uma diferença no TMS de $25,52 \pm 1,66$ até $75,65 \pm 3,22$. Novamente a maior dificuldade apresentada na classificação de diferentes texturas foi entre ES, IS e PB apresentando uma acurácia média do modelo de 78,12%.

Para melhor identificação, foi montada a Tab. IV com as acurácias médias:

TABELA IV. VALOR DA ACURÁCIA DA IDENTIFICAÇÃO DAS DIFERENTES TEXTURAS PARA CADA UM DOS MODELOS DE NEURÔNIOS PROPOSTOS

Modelos de neurônios	Acurácia Média
TP	78,12%
RS	73,75%
IB	79,37%
CH	78,12%
FS	80,62%
LTS	81,25%
TC	78,12%
RZ	79,37%

IV. DISCUSSÃO

Com os dados foi possível verificar que para cada um dos 8 diferentes modelos propostos por Izhikevich foram obtidos diferentes resultados, como é possível visualizar nas Tab. II e III quando comparado os valores do CV-ISI e do TMS da

mesma textura. Junto com isso também se repara que, mesmo com as mudanças, é possível observar certas características de determinadas texturas, como o CV-ISI de TT estar sempre entre os menores valores e seu TMS junto com o do PCO também estarem menores que os apresentados por outras texturas independente do modelo.

Também é possível notar que as texturas que apresentaram maior dificuldade de separabilidade durante as matrizes de confusão na Fig. 2, como ES e IS, possuem nas Tab. II e III valores muito próximos de CV-ISI e TMS pois características entre as texturas, como a complacência, são semelhantes. Então, conforme está apresentado na Tab. IV, não houve uma variação expressiva da acurácia média entre os diferentes modelos de Izhikevich, sendo o menor deles o RS com, 73,75% e o maior o LTS com 81,25% de acurácia na predição das texturas.

Comparando com a literatura encontra-se a utilização de modelos não inspirados pelo modelo sensorial tátil, como a utilização de redes bayesianas conseguindo uma acurácia de classificação entre 8 texturas de 95% [11]. Modelos fisiologicamente inspirados, como o de Friedl [12] conseguiram uma acurácia média de 65% para 18 diferentes texturas e Gupta [2] utilizando a mesma base de dados desse artigo, conseguiu, utilizando apenas um taxel, uma acurácia de 73%. É importante também apontar a necessidade de modelos fisiologicamente inspirados para a segunda camada de neurônios do sistema somatossensorial, como os neurônios cuneiformes [6] para uma eficiência mais próxima da biológica.

V. CONCLUSÃO

Conclui-se que existem diferenças entre a capacidade de classificação para os 8 modelos propostos por Izhikevich. Os resultados mostram que o modelo LTS obteve a melhor distinção dos diferentes tipos de textura, com uma acurácia média de 81,25%, já o modelo RS obteve a menor acurácia, percebe-se existe uma diferença percentual do melhor para o pior modelo de 7,50%.

Apesar dos resultados estarem próximos aos encontrados na literatura destaca-se que ainda é necessário a busca de modelos inspirados no processamento do sistema somatossensorial como um todo, onde seria possível obter a eficiência biológica, a partir de uma rede neural bioinspirada, a partir de modelos que simulem os neurônios secundários e terciários fisiológicos para uma melhor classificação e segregação de estímulos codificados por sensores táteis artificiais.

REFERÊNCIAS

- [1] A. Nakagawa-Silva, N. V. Thakor, J. J. Cabibihan, and A. B. Soares, "A Bio-Inspired Slip Detection and Reflex-Like Suppression Method for Robotic Manipulators," *IEEE Sens. J.*, vol. 19, no. 24, pp. 12443–12453, 2019, doi: 10.1109/JSEN.2019.2939506.
- [2] A. K. Gupta, A. Nakagawa, N. F. Lepora, and N. V. Thakor, "Spatio-temporal encoding improves neuromorphic tactile texture classification," *IEEE Sens. J.*, vol. XX, no. XX, pp. 1–1, 2021, doi: 10.1109/jсен.2021.3087511.
- [3] Y. Zhengkun and Z. Yilei, "Recognizing tactile surface roughness with a biomimetic fingertip: A soft neuromorphic approach," *Neurocomputing*, vol. 244, pp. 102–111, 2017, doi: 10.1016/j.neucom.2017.03.025.
- [4] D. Kumar, R. Ghosh, A. Nakagawa-Silva, A. B. Soares, and N. V. Thakor, "Neuromorphic approach to tactile edge orientation estimation using spatiotemporal similarity," *Neurocomputing*, vol. 407, pp. 246–258, 2020, doi: 10.1016/j.neucom.2020.04.131.
- [5] L. E. Osborn *et al.*, "Prosthesis with neuromorphic multilayered e-dermis perceives touch and pain," *Sci. Robot.*, vol. 3, no. 19, pp. 1–11, Jun. 2018, doi: 10.1126/scirobotics.aat3818.
- [6] U. B. Rongala, A. Spanne, A. Mazzoni, F. Bengtsson, C. M. Oddo, and H. Jörntell, "Intracellular dynamics in cuneate nucleus neurons support self-stabilizing learning of generalizable tactile representations," *Front. Cell. Neurosci.*, vol. 12, no. July, pp. 1–25, 2018, doi: 10.3389/fncel.2018.00210.
- [7] E. M. Izhikevich, "Simple model of spiking neurons," *IEEE Trans. Neural Networks*, vol. 14, no. 6, pp. 1569–1572, 2003, doi: 10.1109/TNN.2003.820440.
- [8] V. E. Abraira and D. D. Ginty, "The sensory neurons of touch," *Neuron*, vol. 79, no. 4, pp. 618–639, 2013, doi: 10.1016/j.neuron.2013.07.051.
- [9] M. Rasouli, Y. Chen, A. Basu, S. L. Kukreja, and N. V. Thakor, "An extreme learning machine-based neuromorphic tactile sensing system for texture recognition," *IEEE Trans. Biomed. Circuits Syst.*, vol. 12, no. 2, pp. 313–325, 2018, doi: 10.1109/TBCAS.2018.2805721.
- [10] A. Roth and M. C. W. van Rossum, "Modeling Synapses," *Comput. Model. Methods Neurosci.*, no. November 2014, pp. 139–160, 2013, doi: 10.7551/mitpress/9780262013277.003.0007.
- [11] J. A. Fishel and G. E. Loeb, "Bayesian exploration for intelligent identification of textures," *Front. Neurobot.*, vol. 6, no. JUNE, pp. 1–20, 2012, doi: 10.3389/fnbot.2012.00004.
- [12] K. E. Friedl, A. R. Voelker, A. Peer, and C. Eliasmith, "Human-Inspired Neurobotic System for Classifying Surface Textures by Touch," *IEEE Robot. Autom. Lett.*, vol. 1, no. 1, pp. 516–523, 2016, doi: 10.1109/LRA.2016.2517213.