

Uso de um Único Neurônio Cuneiforme na Classificação de Texturas Naturalísticas

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

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

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

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

Abstract— The skin is the interface that allows us to interact with the external environment through the sense of touch. Researchers in the field of neuromorphic engineering are looking for sensory models with the same biological efficiency as human touch for applications in prosthetics and robotics. However, it is a challenge to interpret and classify high-density tactile information arising from artificial primary afferents. It is known that the cuneiform nucleus combines and segregates tactile information from the primary afferents. Inspired by the physiology of cuneiform neurons, this work evaluates the ability of a neuromorphic neural network to classify eight naturalistic textures using a single cuneiform neuron in the output layer. Two metrics were extracted from the output of this neural network and used as a feature vector for a support vector machine (SVM). The results showed that the model obtained an average accuracy above 71% in the classification of textures and is in accord with the physiological aspects of cuneiform neurons.

Keywords — Neuromorphic engineering, Texture Classification, Neuromorphic Neural Network, Cuneate Neuron.

I. INTRODUÇÃO

A pele é a interface que permite a nossa interação com ambiente externo e obtenção de informações táteis a partir de seus aproximados 17 mil mecanorreceptores, também conhecidos como aferentes primários [1], [2]. Esses aferentes podem ser classificados em dois tipos, aferentes de adaptação rápida (AR) e lenta (AL). Eles são os responsáveis por transduzir sensações, como pressão e vibração, em potenciais de ação que serão processados e interpretados pelo sistema somatossensorial [1], [3].

Recentemente diversos estudos foram realizados no campo da engenharia neuromórfica para desenvolver sistemas inspirados nas arquiteturas neurais e nas funções do sistema nervoso objetivando atingir a eficiência computacional biológica [4]. Dentre as diversas linhas da engenharia neuromórfica, destaca-se o tato neuromórfico, que se baseia na capacidade do sistema somatossensorial em interpretar as diversas sensações táteis a partir da combinação dos potenciais de ação dos diferentes aferentes primários [4], [5]. O tato neuromórfico abrange tanto a classificação de padrões táteis, como rugosidade [5], textura [6], orientação de borda [4], [7], quanto a restauração da retroalimentação tátil em próteses a partir de modelos bioinspirados de estimulação cutânea [8] ou invasiva [9] através da eletroestimulação [10].

A restauração da retroalimentação tátil ainda é um desafio devido a incapacidade tecnológica de restaurar a mesma quantidade de sensores táteis perdidos em uma amputação com uma alta densidade de pontos de estimulação. Dessa forma, faz-se necessário desenvolver modelos capazes de combinar e representar de maneira generalizável uma alta densidade de sensores artificiais em poucos canais de estimulação. Ademais, esses modelos também seriam úteis na classificação de propriedades de matérias, como texturas.

Inspirados na capacidade de aprendizado e generalização núcleo cuneiforme, região responsável pelo primeiro processamento sensorial advindos do membro superior, Rongala et al. (2018) propôs um modelo neural do núcleo cuneiforme. Esse modelo é capaz de reproduzir a dinâmica da membrana intrínseca e a distribuição altamente especificada dos pesos sinápticos observados em neurônios cuneiformes in vivo. Também implementa o aprendizado sináptico dos pesos excitatórios dos aferentes primários e dos pesos inibitórios de interneurônios do núcleo cuneiforme [11]. Esse modelo se mostrou eficiente na classificação de texturas naturalísticas em diferentes condições, comprovando a sua alta capacidade de generalização e representação de informações táteis [12].

Ainda é um desafio combinar uma alta densidade de informações advindas de aferentes primários para possibilitar a classificação de estímulos táteis em sistemas embarcados, onde a utilização de uma rede de neurônios secundários não seria viável devido ao alto custo computacional. Assim, inspirado no modelo do núcleo cuneiforme proposto em [11] e na necessidade de desenvolver modelos capazes de combinar e segregar uma alta densidade de informações táteis, esse trabalho tem o objetivo de avaliar o uso de um único neurônio cuneiforme (aferente secundário), na classificação de texturas naturalísticas e segregação de informações táteis artificiais.

II. MATERIAS E MÉTODOS

Para avaliar o uso do um neurônio cuneiforme na segregação de informações táteis foi implementada uma rede neural biologicamente inspirada no processamento somatossensorial. A rede é composta por duas camadas, a primeira composta por 32 aferentes primários e a segunda por um neurônio cuneiforme. A saída do neurônio é um sinal pulsátil, binarizado, onde 1 representa a presença de um *spike*, que corresponde a um potencial de ação.

Para avaliar a capacidade de um único neurônio cuneiforme em classificar texturas foram extraídas duas

características da saída do neurônio, a Taxa Média de *Spikes* (TMS) por tempo em segundos e o Coeficiente de Variação dos Intervalos entre *Spikes* (CV_IS), que foram utilizadas como vetor de características em uma máquina de vetor de suporte (SVM).

A Fig. 1 representa um diagrama de blocos da metodologia que será detalhada nos próximos tópicos. Em suma, dados obtidos por um sensor de força de oito texturas naturalísticas foram utilizados como entrada de uma rede neural neuromórfica inspirada no processamento somatossensorial, a primeira camada dessa rede é composta por aferentes primários (mecanorreceptores) e a segunda pelo aprendizado sináptico e um neurônio cuneiforme. A saída da rede neural é um vetor binário, *spikes*, para cada amostra de textura. Desse vetor foram extraídas as duas características, TMS e CV_IS. Essas características foram utilizadas como vetor de características de um classificador (SVM).

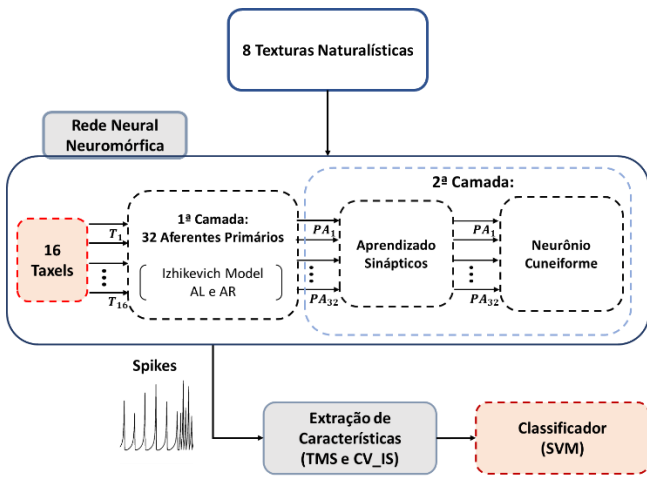


Fig. 1. Diagrama de blocos da metodologia implementada para validação da rede neural neuromórfica.

A. Base de Dados

Os dados utilizados para o desenvolvimento do trabalho pertencem a uma base de dados desenvolvida por Gupta et al. (2021) [13] composta por coletas de palpção ativa de 8 texturas naturalística realizadas por uma mão robótica. A mão estava equipada com um sensor tátil piezoresistivo com 16 pontos sensíveis a pressão (taxels) organizados em uma grade 4x4. Os dados utilizados foram amostrados em uma frequência de 1000 Hz, com uma velocidade de palpção constante de 10 mm/s e força normal igual a 1 N. Para cada textura existem 20 coletas, sendo as texturas nomeadas como Piso 1 (P1), Piso 2 (P2) e Piso 3 (P3), Papel Ondulado (PO), Piso de Borracha (PB), Tapete Têxtil (TT), Esponja (ES) e Isopor (IS).

B. Pré-Processamento dos Dados

Os sinais de cada um dos 16 taxels foram filtrados por um filtro passa-baixa butterworth de 4ª ordem com frequência de corte igual a 30 Hz e normalizados em relação a amostra de maior amplitude e de menor amplitude, conforme (1).

$$n_i = \frac{x_i - v_{m\acute{a}x}}{v_{m\acute{a}x} - v_{m\acute{i}n}} \quad (1)$$

onde n_i é o valor normalizado de um taxel na posição i ; x_i é a amostra na posição i ; $v_{m\acute{a}x}$ é a amostra de maior amplitude da coleta e; $v_{m\acute{i}n}$ é a amostra de menor amplitude da coleta.

O sinal normalizado foi segmentado em 6 segundos na fase de palpção ativa, contendo 6000 amostras. Ele foi utilizado para gerar a corrente de entrada dos neurônios da primeira camada modelados para simular aferentes táteis primários (mecanorreceptores).

C. 1ª Camada: Aferentes Primários – Modelo de Izhikevich

Na primeira camada, o sinal tátil pré-processado proveniente de cada taxel do sensor é enviado a 2 aferentes primários modelados segundo o método proposto por Izhikevich (2003) para simular as respostas dos mecanorreceptores AR e AL [14]. Como o sensor tátil possui 16 taxels, a primeira camada é composta por 32 mecanorreceptores.

O modelo de Izhikevich é capaz de reproduzir diferentes padrões de taxa de disparo de neurônios biológicos. O modelo é composto por um sistema de equações diferenciais de segunda ordem, sendo o potencial de membrana do neurônio descrito em (2) e a variável de recuperação de membrana descrita em (3) [14]. O restabelecimento do potencial de membrana, após um potencial de ação, e da variável de recuperação é modelado através de uma função não linear onde v , ao atingir limiar de 30 mV reseta o estado do neurônio como é descrito em (4).

$$\frac{dv}{dt} = 0.04v^2 + 5v + 140 - u + I(t) \quad (2)$$

$$\frac{du}{dt} = a(bv - u) \quad (3)$$

$$\text{Se } v \geq 30\text{mV}, \text{ ent\~{a}o } \begin{cases} v \leftarrow c \\ u \leftarrow u + d \end{cases} \quad (4)$$

onde v representa o potencial de membrana do neurônio, u a variável de recuperação, $I(t)$ a corrente sináptica (corrente de entrada), t o tempo em escala de milissegundos. Os parâmetros a , b , c e d descrevem respectivamente a escala de tempo de u ; a sensibilidade da variável u a flutuações do potencial de membrana; o valor de potencial de repouso da membrana (em mV); o valor de redefinição de u após um disparo.

A partir dos parâmetros (a , b , c e d) é possível modelar diferentes tipos de neurônios [14]. Na Tab. 1 são apresentados os valores dos parâmetros utilizados na implementação do modelo de Izhikevich para cada tipo de mecanorreceptor utilizados nesse trabalho.

TABELA I. PARÂMETROS DO MODELO DE IZHKEVICH

Variáveis	a	b	c	d
AR	0,1 s ⁻¹	0,2	-65 mV	2 mV
AL	0,02 s ⁻¹	0,2	-65 mV	8 mV

Como os mecanorreceptores de adaptação rápida são sensíveis apenas a fases transientes dos estímulos, foi utilizada a derivada do sinal normalizado associada a um ganho de 3000 antes de ser utilizado como corrente de entrada do modelo AR, conforme representado em (5). Para o modelo AL a corrente de entrada era o sinal normalizado com um ganho de 20 para ajuste da escala da corrente, conforme (6).

$$I(t)_{AR} = \frac{dV_{taxel_n}}{dt} * G_{AR} \quad (5)$$

$$I(t)_{AL} = V_{taxel_n} * G_{AL} \quad (6)$$

Onde $I(t)_{AR}$ e $I(t)_{AL}$ são as correntes de entrada do Modelo de Izhikevich para os aferentes de adaptação rápida e lenta respectivamente, V_{taxel_n} é o sinal normalizado de cada taxel e G_{AR} é o ganho para o modelo neural de adaptação rápida igual a 3000, e G_{AL} é o ganho para o modelo de adaptação lenta igual a 20.

Segundo o modelo de Izhikevich, quando o potencial de membrana atinge o limiar de 30 mV é considerado que o neurônio gerou um disparo de potencial de ação (*spike*). Assim, toda vez que o neurônio dispara a saída binária do modelo (neuromórfica) é igual a 1 e ao contrário igual a 0. Esse sinal binário para cada aferente foi utilizado como entrada da segunda camada neural composta por um neurônio cuneiforme.

D. 2ª Camada: Aferente Secundário – Neurônio Cuneiforme

Para a implementação do neurônio do núcleo cuneiforme foi utilizado o modelo proposto por Rongala et al. (2018). Esse modelo é baseado no *Exponential Integrate and Fire* (EIF), juntamente com uma detalhada modelagem da atividade dos canais de cálcio voltagem dependentes de baixo limiar e dos canais de potássio cálcio-dependentes. A dinâmica completa do potencial de membrana dos neurônios cuneiformes é descrita em (7).

$$C_m \frac{dV_m}{dt} = I_L + I_{spike} + I_{ion} + I_{ext} + I_{syn} \quad (7)$$

em que C_m é a capacitância da membrana; V_m é o potencial de membrana do neurônio cuneiforme; I_L é a corrente de fuga do neurônio; I_{spike} é a corrente de pico que recria o início do potencial de ação e a despolarização rápida dos neurônios cuneiformes; I_{ion} é a corrente iônica resultante da somatória das correntes dos canais de cálcio voltagem dependentes e dos canais de potássio dependentes de cálcio; I_{ext} é a corrente externa que pode ser injetada no neurônio, neste estudo igual a 0; e, finalmente I_{syn} é a corrente sináptica, onde cada sinapse individual (i) é ativada por um mecanorreceptor, descrita em (8).

$$I_{syn} = g_{max} \left[\sum_i w_{exc,i} \exp(-\tau(t - t^*)) (E_{rev,exc} - V_m) + \sum_i w_{inh} \exp(-\tau(t - t^*)) (E_{rev,inh} - V_m) \right] \quad (8)$$

em que $w_{exc,i}$ é o peso sináptico excitatório; t^* é o tempo em que ocorre uma *spike* e; w_{inh} é o peso inibitório, g_{max} é a condutância máxima, igual 23×10^{-8} S; τ é uma constante de tempo de decaimento de 6,4 ms. O aprendizado excitatório é descrito em (9), sendo que a potencialização dos pesos excitatórios ocorre quando a atividade local de cálcio de uma sinapse (mecanorreceptor com o neurônio cuneiforme) está

altamente correlacionada com a atividade total de cálcio do neurônio cuneiforme, o oposto essa sinapse será depreciada.

$$\Delta w_{exc,i} = \int_{t_0}^{t_{max}} \left\{ \left(A_{Tot}^{Ca^{2+}}(t) - (Avg_{A_{Tot}^{Ca^{2+}}} * Syn_{EQ}) \right) * A_{Loc}^{Ca^{2+}}(t) \right\} * K * dt \quad (9)$$

em que $A_{Tot}^{Ca^{2+}}$ é a atividade total de cálcio do neurônio cuneiforme; $Avg_{A_{Tot}^{Ca^{2+}}}$ é a média dos três últimos valores da atividade total de cálcio; Syn_{EQ} é o equilíbrio sináptico; $A_{Loc}^{Ca^{2+}}$ é atividade local de cálcio devido a uma sinapse e; K é um fator de ganho.

A atualização do peso inibitório total (w_{inh}) é baseada na taxa de disparo dos canais de cálcio, e está relacionada com a atividade total de cálcio e representa o peso da sinapse inibitória de um interneurônio do núcleo cuneiforme. Assim o aumento na atividade de cálcio resulta no aumento do peso inibitório e a diminuição na atividade de cálcio resulta no decaimento do peso inibitório.

Para a determinação dos pesos excitatórios e inibitórios foi realizado treinamento em *4-Fold* utilizando 1 segundo de 15 amostras de cada uma das oito texturas apresentadas de maneira aleatória seguindo uma distribuição uniforme. Cada amostra foi apresentada 20 vezes, resultado em 2400 ciclos de treinamento. Para todos os pacotes de treinamento foram utilizados os mesmos pesos iniciais. Os pesos excitatórios iniciais, foram gerados aleatoriamente, com valores entre 0,001 e 0,5, seguindo uma distribuição gaussiana. O peso inibitório inicial foi definido em 0,125 conforme proposto em [11].

Após a determinação dos pesos sinápticos, foi verificado que os pesos finais dos 4 treinamentos ficaram próximos então optou-se por validar apenas o primeiro treinamento. Para isso foi calculado o potencial de membrana do neurônio cuneiforme do primeiro pacote de treinamento para todas as amostras das texturas durante os seis segundos e foi determinada a saída binária desse neurônio, um vetor de *spikes*.

E. Indices de Avaliação

Para avaliação do modelo e comparação dos resultados encontrados foram calculadas duas métricas a Taxa Média de *Spikes* (TMS) e o Coeficiente de Variação dos Intervalos entre *Spikes* (CV_IS). A TMS descrita em (10) descreve a taxa global de disparos, frequência média, do modelo neuromórfico.

$$TMS = \frac{nSpikes}{T} \quad (10)$$

em que $nSpikes$ corresponde a quantidade de *spikes* no tempo (T) em segundos, 6 segundos.

O CV_IS fornece uma estimativa da variação dos intervalos de tempo de *spikes* consecutivos, e é descrito em (11).

$$CV_{IS} = \frac{\sigma_{is}}{\mu_{is}} \quad (11)$$

em que σ_{is} é o desvio padrão e μ_{is} é a média do vetor is , que contém a diferença de tempo entre dois *spikes* consecutivos, o intervalo entre *spikes*, do vetor binarizado de saída do modelo.

Foi avaliado se esses índices correspondem a um vetor de características capaz de separar as texturas em um espaço vetorial, indicando que a informação para detectar diferentes texturas está presente na resposta do neurônio cuneiforme. Para isso, os índices obtidos da saída rede neural foram aplicados a uma máquina de vetor de suporte (SVM) de kernel gaussiano e sua performance foi avaliada usando validação cruzada do tipo *leave-one-out* com as 20 amostras de texturas.

III. RESULTADOS

A. Aprendizagem sináptica – 2ª Camada

Na Fig. 2 são apresentados os pesos excitatórios dos 32 aferentes primários. Observa-se na Fig. 2 A que os pesos iniciais possuíam valores entre 0 e 0,5 e que após o treinamento conforme representado na Fig. 2 B constata-se que apenas dois aferentes primários (2 e 24) obtiveram peso sináptico acima de 0,5, ou seja, possuem sinapses excitatórias significativas.

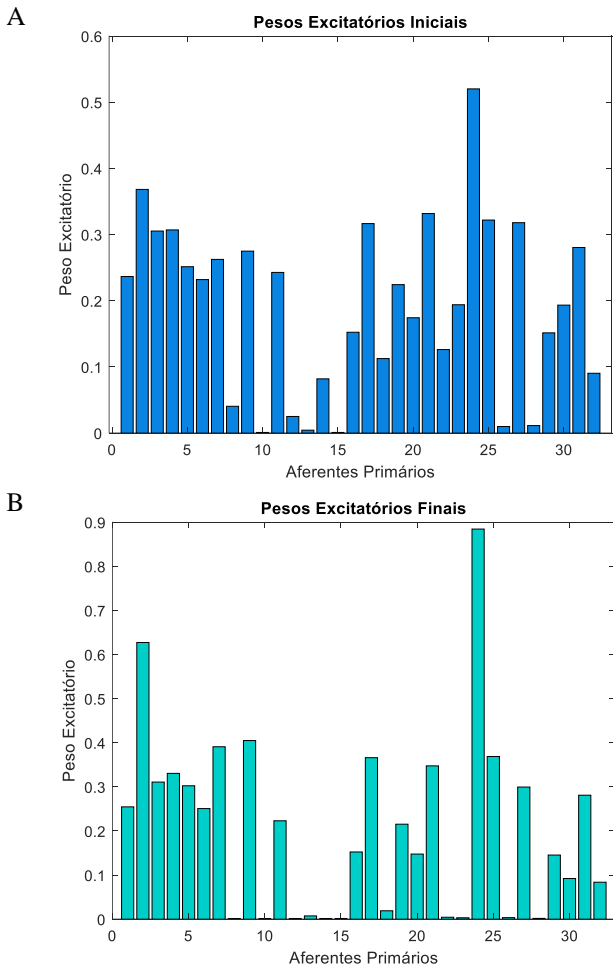


Fig. 2. A) Pesos excitatórios iniciais dos 32 aferentes primários B) Pesos excitatórios finais após o aprendizado sináptico.

A Fig. 3 representa a evolução do peso inibitório ao longo do treinamento. Sendo o peso inibitório final igual a 0,1945.

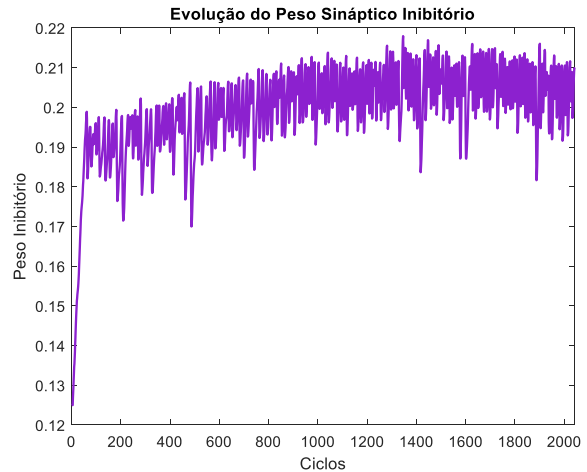


Fig. 3. Evolução do peso sináptico inibitório ao longo do treinamento.

Esses pesos finais foram utilizados no cálculo da corrente sináptica proposto pelo modelo e determinação da variação do potencial de membrana do neurônio cuneiforme para os 6 segundos de cada amostra de textura.

B. Dispersão das Texturas

Para avaliar a dispersão das texturas foram extraídas duas características do vetor de *spikes* da saída da rede neural neuromórfica para cada amostra de textura, o valor dessas características é representado na Fig. 4, onde é possível observar que a TMS do neurônio cuneiforme varia a depender da textura numa faixa de 20 a 140 Hz e que o CV_{IS} variou na faixa de 1,3 a 3. Através do *boxplot* é possível verificar a separabilidade das texturas a depender das características que foram extraídas e que algumas texturas a saída do modelo possui um comportamento bem similar como é o caso do IS e da EP.

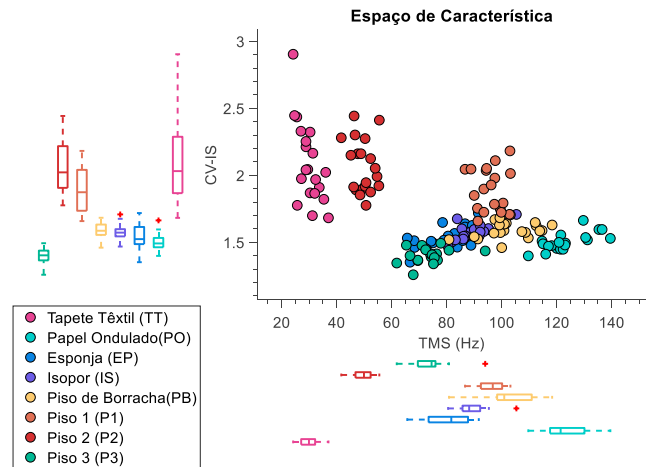


Fig. 4. Espaço de características das amostras para as oito texturas.

Essas características foram utilizadas como parâmetros de entrada de uma SVM e foi realizada uma validação cruzada do tipo *leave-one-out*. A Fig. 5 representa os resultados obtidos na classificação das diferentes texturas pela SVM.

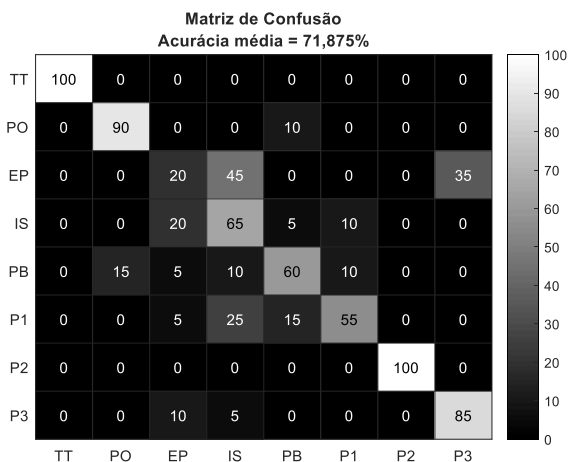


Fig. 5. Matriz de confusão do resultado da classificação da SVM para as diferentes texturas.

IV. DISCUSSÃO

A rede neural neuromórfica aqui implementada foi baseada no primeiro estágio de processamento somatossensorial que ocorre no núcleo cuneiforme [15] e no modelo neural bioinspirado proposto em [11]. Os resultados encontrados para os pesos excitatórios sinápticos finais demonstram estar de acordo com dados fisiológicos de neurônios cuneiformes, uma vez que, foi demonstrado que um único neurônio cuneiforme biológico pode receber entradas de centenas de aferentes primários, porém apenas em torno de 4 a 8 aferentes irão possuir pesos excitatórios significativos, existindo inclusive sinapses silenciosas [16]. Observa-se na Fig. 3 que no modelo implementado apenas dois mecanorreceptores possuíam pesos excitatórios significativos após o treinamento e que para alguns aferentes primários esse peso final era aproximadamente igual a 0 (sinapse silenciosa).

A acurácia média encontrada na classificação pela SVM foi igual a 71,875% sendo abaixo do que encontrado em [13] para os mesmos dados, nesse estudo foi encontrado uma acurácia média de 73% em uma classificação utilizando um único taxel modelado para simular um aferente primário do tipo AL, porém além da TMS e CV-IS os autores também utilizaram o fator fano na classificação.

Apesar da acurácia média não ter sido alta, ela é próxima da encontrada [13] na classificação por único taxel, e o modelo proposto possui a característica de selecionar, pelo o aprendizado sináptico, os taxels de maior relevância de maneira não supervisionada baseada na dinâmica intracelular do neurônio cuneiforme modelado. Ademais esse modelo permite a combinação de mais aferentes secundários, o que possibilitaria uma melhoria na performance da classificação, assim como foi feito em [12], onde os autores utilizaram 25 neurônios cuneiformes na classificação de texturas naturalísticas em diferentes condições de coletas, diferentes velocidades de palpação, atingindo acurácia na classificação acima de 90%. Ademais nesse estudo os autores acrescentam um percentual de ruído no aferentes primários para resultar em um aprendizado mais robusto, aqui foi utilizado apenas dados coletados sem adição de ruído.

V. CONCLUSÃO

Inspirado no modelo neural do núcleo cuneiforme aqui foi avaliado a capacidade de segregação e classificação de texturas naturalísticas de um único neurônio secundário na

saída de uma rede neural neuromórfica. A partir dos resultados foi demonstrado que o modelo implementado é capaz de selecionar os taxels de maior relevância em classificação de estímulos táteis e obtendo uma acurácia próxima a encontrada na literatura utilizando uma classificação single taxel [13].

Conclui-se que o modelo implementado com a saída de um único neurônio cuneiforme pode ser utilizado na classificação de estímulos táteis. Como trabalho futuro é interessante avaliar se o aumento da variabilidade dos estímulos do treinamento, a partir da adição de ruído nos dados dos aferentes primário, e também a ampliação gradual da quantidade de neurônios secundários na camada de saída poderia resultar em uma melhoria na performance.

AGRADECIMENTOS

Agradecimentos à CNPQ, CAPES e FAPEMIG, pelo apoio financeiro e à Universidade Federal de Uberlândia (UFU) e ao BIOLAB-FEELT-UFU pela disponibilização de estrutura física.

REFERENCES

- [1] 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.
- [2] M. F. Bear, B. W. Connors, M. A. Paradiso, and C. A. S. G. Caps, *Neurociências: Desvendando o Sistema Nervoso*, 3rd ed. SÃO PAULO: Lippincott Williams & Wilkins, 2008.
- [3] R. S. Johansson and J. R. Flanagan, "Coding and use of tactile signals from the fingertips in object manipulation tasks," *Nat. Rev. Neurosci.*, vol. 10, no. 5, pp. 345–359, 2009, doi: 10.1038/nrn2621.
- [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] 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.
- [6] 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, pp. 1–8, 2020, [Online]. Available: <http://arxiv.org/abs/2010.14184>.
- [7] U. B. Rongala *et al.*, "Tactile decoding of edge orientation with artificial cuneate neurons in dynamic conditions," *Front. Neurobot.*, vol. 13, no. July, pp. 1–10, 2019, doi: 10.3389/fnbot.2019.00044.
- [8] E. D'Anna *et al.*, "A somatotopic bidirectional hand prosthesis with transcutaneous electrical nerve stimulation based sensory feedback," *Sci. Rep.*, vol. 7, no. 1, pp. 1–15, 2017, doi: 10.1038/s41598-017-11306-w.
- [9] G. Valle *et al.*, "Biomimetic Intraneural Sensory Feedback Enhances Sensation Naturalness, Tactile Sensitivity, and Manual Dexterity in a Bidirectional Prosthesis," *Neuron*, vol. 100, no. 1, pp. 37–45.e7, 2018, doi: 10.1016/j.neuron.2018.08.033.
- [10] B. Stephens-frripp, G. Alici, and R. Mutlu, "A Review of Non-Invasive Sensory Feedback Methods for Transradial Prosthetic Hands," *IEEE Access*, vol. 6, pp. 6878–6899, 2018, doi: 10.1109/ACCESS.2018.2791583.
- [11] 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.
- [12] U. B. Rongala, A. Mazzoni, A. Spanne, H. Jörntell, and C. M. Oddo, “Cuneate spiking neural network learning to classify naturalistic texture stimuli under varying sensing conditions,” *Neural Networks*, vol. 123, pp. 273–287, 2020, doi: 10.1016/j.neunet.2019.11.020.
- [13] 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/jsen.2021.3087511.
- [14] 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.
- [15] H. Jörntell, F. Bengtsson, P. Geborek, A. Spanne, A. V. Terekhov, and V. Hayward, “Segregation of tactile input features in neurons of the cuneate nucleus,” *Neuron*, vol. 83, no. 6, pp. 1444–1452, 2014, doi: 10.1016/j.neuron.2014.07.038.
- [16] F. Bengtsson, R. Brasselet, R. S. Johansson, A. Arleo, and H. Jörntell, “Integration of Sensory Quanta in Cuneate Nucleus Neurons In Vivo,” *PLoS One*, vol. 8, no. 2, 2013, doi: 10.1371/journal.pone.0056630.