

ANÁLISE E DESENVOLVIMENTO DE UM MODELO DE CIRCUITO NEUROMÓRFICO DIGITAL EXTREME LEARNING MACHINE (ELM)

Fábio Pereira da Silva Stolf¹ (IC), Gabriel Antonio Fanelli de Souza (PQ)¹

¹Universidade Federal de Itajubá.

Palavras-chave: Extreme learning machine, modelo, biases.

Introdução

Este trabalho de Iniciação Científica teve como objetivo a análise do comportamento e o desenvolvimento de um modelo de rede com arquitetura Extreme Learning Machine (ELM) na forma de um circuito neuromórfico digital para aprender diferentes superfícies. Destaca-se que esse projeto de pesquisa é uma continuação de um trabalho de Iniciação Científica anterior realizado pelo Grupo de Microeletrônica da Universidade Federal de Itajubá, trabalho esse que visou desenvolver um circuito neuromórfico analógico com a tecnologia CMOS e função de ativação ReLU [4]. Desse modo, esse trabalho utiliza a mesma topologia de rede explorando as vantagens de uma interface digital, como a facilidade de interação com outras interfaces digitais, a maior imunidade ao ruído e simplificação do projeto por utilizar uma implementação em Verilog.

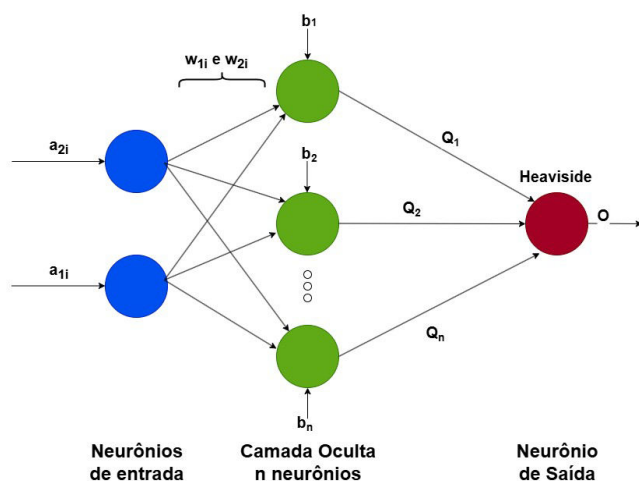


Figura 1 - Topologia da rede ELM

Uma rede ELM é uma *single-hidden-layer feedforward network* (SLFN) que possui apenas uma camada oculta, como mostrado na Figura 1. Porém, esse tipo de modelo se diferencia dos demais por possuir pesos de entrada e viéses (biases) fixos e aleatórios, permitindo com que o peso de saída seja ajustado pelo

método dos mínimos quadrados. Assim, o treinamento se torna menos exigente computacionalmente, o que reduz o tempo de processamento e aumenta a eficiência energética [1, 2].

Metodologia

A metodologia foi dividida em três etapas: o desenvolvimento de um script, no Octave, que simula uma rede neural artificial Extreme Learning Machine (ELM); o desenvolvimento de um circuito digital, em Verilog pelo Quartus, que mimetiza o comportamento da rede; testes para identificar valores ótimos para parâmetros de viéses (biases) e número de neurônio na camada oculta, dado uma superfície alvo.

O modelo de rede foi desenvolvido onde cada neurônio possui dois valores de entrada, combinações 1 a 128. Os pesos de entrada são aleatórios e potências de dois entre 2^1 e 2^7 . A rede aceita apenas pesos de entrada e biases positivos e é utilizada a função degrau (Heaviside) para o processo de aprendizado da superfície.

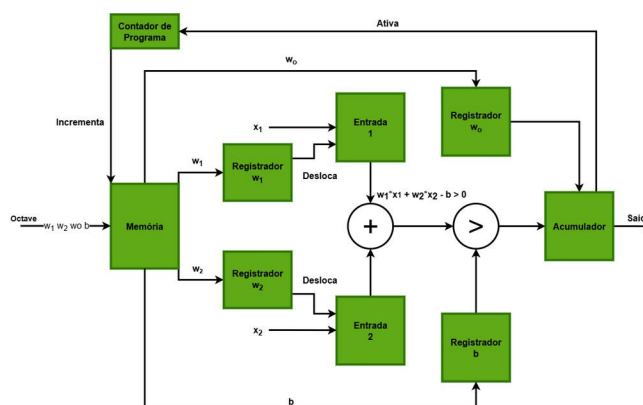


Figura 2 - Diagrama simplificado do circuito

O algoritmo desenvolvido no Octave possibilita o treinamento em cinco superfícies alvo distintas com crescente nível de dificuldade de aprendizado, sendo: um plano linear, uma superfície senoidal, um parabolóide, um relevo gaussiano e a superfície senoide

e cossenoide.

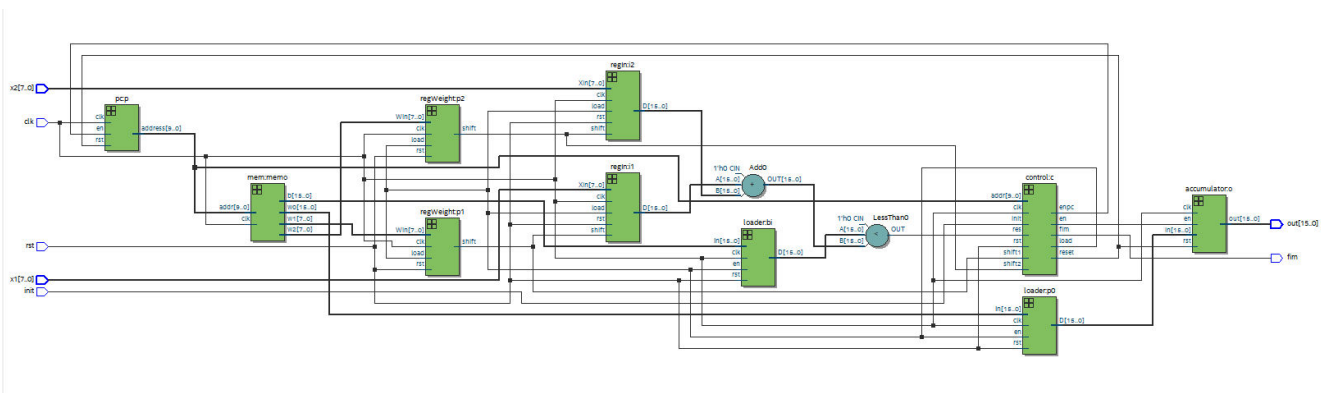


Figura 3 - Circuito neuromórfico digital

O circuito neuromórfico recebe os valores dos pesos de entrada, dos vieses e do peso de saída advindos do algoritmo, convertidos para a base binária, que são armazenados em um bloco de memória ROM (read only memory). Como os pesos de entrada são potências de 2, a multiplicação pelos valores de entrada foi simplificada a um simples deslocamento para a esquerda, que persiste até o registrador das entradas identificar nível lógico alto (1). Em seguida, soma-se os resultados das duas entradas e subtrai-se do bias. Caso o resultado seja positivo, é transmitido o peso de saída para a saída do circuito; caso contrário, o resultado é descartado. E, assim, ocorre para todos os neurônios.

Por fim, foram realizadas simulações no Octave que ajustaram as características da rede buscando minimizar o erro em relação a superfície alvo utilizando o R² como figura de mérito nesse problema de otimização. A primeira simulação procurou o número de neurônios para cada superfície, executando 100 simulações para cada valor de número de neurônios, entre 1 e 500. A segunda simulação iterou 5000 vezes o modelo visando valores de vieses ao podenrar o R² e a quantidade de erros nas iterações. O R² é descrito pela fórmula:

$$R^2 = 1 - \frac{\sum_{i=1}^N (target_{output} - network_{output})^2}{\sum_{i=1}^N (target_{output} - media(target_{output}))^2}$$

Na qual, target_{output} são os pontos da superfície alvo e network_{output} os pontos encontrados pelo modelo.


Resultados e discussão

Para a primeira simulação, adotou-se os vieses como uma combinação de dois intervalos espaçados igualmente com a função ‘linspace()’ do Octave. A primeira faixa utiliza um quinto dos números de neurônios e valores entre 1000 e 5000, a segunda faixa utiliza os neurônios restantes em uma faixa de 10000 a 50000, realizando um tratamento para caso o valor do bias seja superior ao de 2¹⁵ (32768), ele mantém 32768. Assim, foram obtidos os seguintes resultados:

Tabela 1 - R² médio para cada superfície dado o número de neurônios

Superfície	R ² médio	Número de Neurônios
Plano linear	0,9607	150
Senoide	0,8697	200
Paraboloide	0,6594	250
Gaussiana	0,6954	250
Senoide cossenoide	0,6890	300

Figura 4 - Saída da rede - Plano linear



“Do conhecimento acadêmico à transformação sustentável: inovação com validação científica”




Figura 5 - Saída da rede - Senoide




Figura 6 - Saída da rede - Paraboloid




Figura 7 - Saída da rede - Superfície Gaussiana




Figura 8 - Saída da rede - Senoide cossenoide

Para a segunda simulação, adotou-se a superfície senoide cossenoide como referência, com 300 neurônios para buscar valores de biases com a menor quantidades de erro. Esse erro é determinado quando o

R^2 , que deveria ser entre 0 e 1, é menor que 0. Os resultados obtidos foram:

Tabela 2 - Quantidade de erro percentual por bias

Biases	Quantidade de Erro
1	0,58%
2	0,20%
3	0,40%

- Bias 1: um décimo dos neurônios para um intervalo de 500 a 2000 e nove décimos para o intervalo 5000 a 40000.
- Bias 2: um quinto dos neurônios para um intervalo de 1000 a 5000 e nove décimos para o intervalo 10000 a 50000.
- Bias 3: um quarto dos neurônios para um intervalo de 2000 a 6000 e nove décimos para o intervalo 12000 a 60000.

Para todos os casos quando o valor ultrapassa 32768, ele se limita ao mesmo.




Figura 9 - Iterações x R^2 para o bias 1




Figura 10 - Iterações x R^2 para o bias 2

“Do conhecimento acadêmico à transformação sustentável: inovação com validação científica”




Figura 11 - Iterações x R^2 para o bias 3

Os valores do biases indicam que quanto menor seu valor, maior será o processo de aprendizado, porém estará sujeito a ocorrência de mais erros. O oposto também ocorre, quando maior o valor, menor o aprendizado, entretanto, é mais seguro, pois os erros que ocorrerem dificilmente afetam a integridade do modelo, visto que estão próximos do 0. Então, a solução foi dividir o valor dos biases em faixas, dado o número de neurônios, para garantir uma ótima distribuição.

Conclusões

Em síntese, o trabalho comprovou a eficácia da rede ELM implementada com uma interface digital, apresentando resultados satisfatórios para R^2 , que refletem diretamente o quanto o modelo foi capaz de aprender. A otimização dos parâmetros, número de neurônios e bias, demonstraram o potencial que rede ELM possui de aprender as superfícies propostas suficientemente bem para aplicações na vida real, como a predição de problemas em sistemas de energia renovável [3]. Ademais, futuramente, sugerimos a exploração de diferentes funções de ativação para a rede, como a ReLu (rampa linear), um sistema para tratamentos de erros críticos e a migração para uma arquitetura ELM com neurônios Spiking.

Agradecimentos

Agradeço ao PIVIC, a Universidade Federal de Itajubá, ao grupo de microeletrônica e seus colaboradores pelo financiamento. Sou grato ao Gabriel A. F. de Souza pela oportunidade, ajuda e pelo conhecimento adquirido. Por fim, agradeço aos meus amigos Felipe H. Puccinelli e Felipe M. Rodrigues por estarem ao meu lado durante essa jornada.

Referências

- [1] DING, Shifei; XU, Xinzheng; NIE, Ru. Extreme learning machine and its applications. *Neural Computing and Applications*, London: Springer-Verlag, v. 25, p. 549–556, 2014.
- [2] WANG, J.; LU, S.; WANG, S. H.; et al. A review on extreme learning machine. *Multimedia Tools and Applications*, v. 81, p. 41611–41660, Dec. 2022. Disponível em: <https://doi.org/10.1007/s11042-021-11007-7>. Acesso em: 21 ago. 2025.
- [3] DEL SER, J.; CASILLAS-PEREZ, D.; CORNEJO-BUENO, L.; PRIETO-GODINO, L.; SANZ-JUSTO, J.; CASANOVA-MATEO, C.; SALCEDO-SANZ, S. Randomization-based machine learning in renewable energy prediction problems: critical literature review, new results and perspectives. *Applied Soft Computing*, v. 118, 108526, 2022. ISSN 1568-4946. Disponível em: <https://doi.org/10.1016/j.asoc.2022.108526>. Acesso em: 23 ago. 2025.
- [4] ALVES, Euller Lucas Mendes; SOUZA, Gabriel Antonio Fanelli de. Análise e implementação de circuito neuromórfico utilizando a arquitetura ELM (Extreme Learning Machine) em hardware. In: SIMPÓSIO DE INICIAÇÃO CIENTÍFICA, 7., 2024, Itajubá. *Anais...* Itajubá: Universidade Federal de Itajubá, 2024.